


UNIVERSIDADE FEDERAL DO PARANÁ

ÂNGELA MARIA KLEIN HENTZ

OBTENÇÃO DE INFORMAÇÕES DENDROMÉTRICAS PARA INVENTÁRIO
FLORESTAL AUTOMATIZADO POR MEIO DE VEÍCULO AÉREO NÃO
TRIPULADO (VANT)

CURITIBA

2018



ÂNGELA MARIA KLEIN HENTZ

OBTENÇÃO DE INFORMAÇÕES DENDROMÉTRICAS PARA INVENTÁRIO
FLORESTAL AUTOMATIZADO POR MEIO DE VEÍCULO AÉREO NÃO
TRIPULADO (VANT)

Tese apresentada ao curso de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutora em Engenharia Florestal.

Orientador: Prof. Dr. Sylvio Péllico Netto

Coorientadora: Profa. Dra. Ana Paula Dalla Corte

Coorientador: Prof. Dr. Michael P. Strager

CURITIBA

2018

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Hentz, Ângela Maria Klein

Obtenção de informações dendrométricas para inventário florestal automatizado por meio de veículo aéreo não tripulado (VANT) / Ângela Maria Klein Hentz. – Curitiba, 2018.
238 f. : il.

Orientador: Prof. Dr. Sylvio Péllico Netto

Coorientadores: Profa. Dra. Ana Paula Dalla Corte

Prof. Dr. Michael P. Strager


Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 10/12/2018.

Área de concentração: Manejo Florestal.

1. Levantamentos florestais. 2. Mapeamento florestal. 3. Fotogrametria aérea. 4. Sensoriamento remoto. 5. Drone. 6. Lasers. 7. Teses. I. Péllico Netto, Sylvio. II. Dalla Corte, Ana Paula. III. Strager, Michael P. IV. Universidade Federal do Paraná, Setor de Ciências Agrárias. V. Título.

CDD – 634.9

CDU – 634.0.58



MINISTÉRIO DA EDUCAÇÃO
SETOR SETOR DE CIÊNCIAS AGRÁRIAS
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA
FLORESTAL


TERMO DE APROVAÇÃO


Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **ANGELA MARIA KLEIN HENTZ** intitulada: **Obtenção de informações dendrométricas para inventário florestal automatizado por meio de veículo aéreo não tripulado (VANT)**, após terem inquirido a aluna e realizado a avaliação do trabalho, são de parecer pela sua Aprovação no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 10 de Dezembro de 2018.


SYLVIO PÉLLICO NETTO
Presidente da Banca Examinadora


EMANUEL ARAÚJO SILVA
Avaliador Externo (UFRPE)


EMERSON ROBERTO SCHOENINGER
Avaliador Externo (Klabin S.A.)


FLAVIO FELIPE KIRCHNER
Avaliador Externo (UFPR)


ANA PAULA DALLA CORTE
Avaliador Interno (UFPR)



AGRADECIMENTOS

Ao meu comitê orientador, composto pelos professores Sylvio Péllico Netto, Ana Paula Dalla Corte e Michael P. Strager pela confiança em minha capacidade para o desenvolvimento deste trabalho, sempre oferecendo apoio em diversos aspectos nestes quatro anos de jornada. Em especial à professora Ana Paula Dalla Corte, que me orientou e compartilhou seus conhecimentos durante todo o decorrer dos períodos de mestrado e doutorado. Meu muito obrigada.

Ao Programa de Pós-Graduação em Engenharia Florestal da Universidade Federal do Paraná pela oportunidade de ingressar no programa e desenvolver esta pesquisa. Aos todos os professores do PPGEF e PPGCG que compartilharam seus conhecimentos, não só em sala de aula, mas se disponibilizando a auxiliar em meu processo de aprendizado no geral. Em especial, ao professor Alexandre Behling pelo importantíssimo auxílio com as análises estatísticas.

A empresa Klabin S.A. pelo imenso apoio na realização deste trabalho, especialmente nas pessoas de Emerson Roberto Schoeninger, Luiz Gastão Burnett, Edinaldo Aparecido Orador, Clewerson Frederico Scheraiber, Ana Beatriz Schikowski e Yuri Accioly que foram apoiadores e contribuidores deste projeto. Ainda, aos funcionários João Silva, Cristiano Oliveira Santos, Jorge Schott, Thiago, Marcelo e Guilherme pelo auxílio em campo e no processamento dos dados.

Aos colegas de Pós-Graduação, em especial a todos do BIOFIX, pelo companheirismo e troca de conhecimentos durante este período. Ainda, em especial as amigas e colegas Ana Beatriz Schikowski e Mônica Anater, pela disponibilidade e auxílio nos vários dias de coleta de dados em campo.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de estudos.

À minha família, em especial aos meus pais e irmãos, pela compreensão das muitas ausências durante este período, e pelo apoio e incentivo para a conclusão desta etapa.

Ao meu marido, amigo e companheiro de todos os momentos, Rafael, pela paciência durante todos estes anos, principalmente durante o período em que estivemos à distância, nunca deixando de acreditar na minha capacidade. Obrigada pelo apoio, carinho e companheirismo sempre!

E a todos que de alguma forma contribuíram para este trabalho.

RESUMO

Este trabalho teve como objetivo analisar o potencial do uso de dados obtidos com sensores passivos embarcados em Veículo Aéreo Não Tripulado (VANT) para obtenção de variáveis de inventário florestal. Para tanto, um talhão de *Eucalyptus urograndis* com 5 anos e dois de *Pinus taeda* com 7 e 16 anos, todos com aproximadamente 3 ha, foram inventariados em censo. Foram mensurados o dap (diâmetro à altura do peito – 1,3 m) e altura, e obteve-se o volume individual com equações polinomiais de 5º grau. Tomou-se a linha e posição de cada árvore na linha, e realizou-se a alocação de todas as árvores em um sistema de coordenadas com apoio de ortomosaicos. Voos com o VANT eBee e câmeras RGB, NIR e Multiespectral foram realizados, objetivando 5 cm de resolução e sobreposição de 80%. As imagens foram processadas com o *software* Pix4D, obtendo-se um ortomosaico, um modelo digital de superfície (MDS) e uma nuvem de pontos para cada câmera. As resoluções dos ortomosaicos variaram entre 5-7 cm para as câmeras RGB e NIR, e entre 10-14 cm para a câmera Multiespectral. Os MDS de cada câmera foram normalizados a partir de dados LiDAR, resultando em um modelo digital de altura de copa (CHM). Os produtos VANT foram utilizados para a detecção individual de árvores, executada a partir de uma ferramenta desenvolvida neste trabalho, chamada TreeDetect e outros três métodos de detecção. Todos os métodos de detecção mostraram-se promissores, porém os resultados da detecção variaram em função dos 3 talhões. A ferramenta TreeDetect apresentou os melhores resultados pela análise de qualidade em todos os talhões, principalmente quando foi aplicada com a banda espectral selecionada (NIR), se comparado ao seu uso com CHM. Para as estimativas das variáveis dendrométricas dap, altura e volume, as copas de todas as árvores alocadas manualmente foram delimitadas, utilizando-se um algoritmo disponível no pacote rLiDAR. Para cada copa foram extraídas informações derivadas dos produtos VANT, classificados como produtos estruturais (CHM e MDS), espectrais (bandas e índices), e de textura GLCM. Essas variáveis foram aplicadas em modelos de regressão múltipla com seleção *stepwise*, em sete combinações. As melhores equações estimativas resultaram em R^2_{aj} e $Syx\%$ variando entre: 0,27-0,58 e 8,98-16,41% para dap, 0,34-0,52 e 5,94-13,87% para altura, e 0,37-0,59 e 18,57-36,99% para volume. O talhão *Eucalyptus* apresentou os melhores resultados e o *Pinus* com 16 anos os piores. A combinação de todas as variáveis apresentou os melhores ajustes em todas as situações. Todas as equações apresentaram resíduos tendenciosos, superestimando as árvores menores e subestimando as maiores, porém a inclusão de um fator de correção calculado em classes de tamanho, permitiu a redução das tendências e melhoria dos ajustes, que atingiram valores de R^2_{aj} acima de 0,70 na maioria dos casos. A aplicação dos modelos estimativos de volume nas árvores detectadas pela ferramenta TreeDetect apresentou resultados muito bons, com erro máximo de 9,09% do volume total do talhão. Portanto, observou-se que dados de VANT podem ser aplicados com sucesso para a detecção de árvores individuais, e subsequente estimativa de variáveis dendrométricas.

Palavras-chave: Drone. Árvore individual. Detecção. LiDAR. Regressão Múltipla.

ABSTRACT

This project had as main objective to evaluate the potential of using Unmanned Aerial Vehicle (UAV) data, and passive sensors, to obtain forest inventory variables. To accomplish this, one *Eucalyptus urograndis* stand with 5 years, and two *Pinus taeda* stands with 7 and 16 years, with approximately 3 ha each, were inventoried at census level. The diameter at breast height (DBH – 1.3 m) and total height of all trees were measured, and the individual volume was obtained using a fifth-degree polynomial equation. The line and position of each tree in the line was also recorded and, with this information each tree was plotted into a coordinate system over an orthomosaic. Flights were made with the UAV eBee and cameras RGB, NIR and Multispectral at an elevation to obtain 5 cm GSD and 80% overlap. The images were processed with Pix4D software, and an orthomosaic, a digital surface model (DSM), and a point cloud were obtained from each camera. The orthomosaic resolutions ranged from 5-7 cm for RGB and NIR cameras, and 10-14 cm for the Multispectral camera. Each camera DSM was normalized with LiDAR data, resulting in a canopy height model (CHM). The UAV products were applied to individual tree detection, performed using a tool called TreeDetect, developed for this project, and three other detection methods. Every detection method presented promising results, but the detection results were variable depending on the three stands. The TreeDetect tool presented the best results considering the quality assessment in all stands, especially when the tool was applied using the spectral band selected (NIR), in comparison with the TreeDetect with the CHM. The crowns of each plotted tree were delimited, using an algorithm available in the rLiDAR package, to predict the variables DBH, height and volume. From each crown, UAV derived metrics were computed, considering structural (CHM and DSM), spectral (bands and indexes) and GLCM textural products. The variables were applied into multiple regression models, with stepwise selection, in seven combinations. The developed equations resulted in R^2_{aj} and $Syx\%$ ranging from 0.27-0.58 and 8.98-16.41% for DBH, 0.34-0.52 and 5.94-13.87% for height, and 0.37-0.59 and 18.57-36.99% for volume. The *Eucalyptus* stand presented the best results and the *Pinus* with 16 years presented the worse results. The combination of all variables provided the best model fit in all situations. All equations presented tendency in the residuals, overestimating the smallest trees and underestimating the largest, therefore the addition of a correction coefficient based in size classes resulted in reduction of those trends and in better fitting values for the equations, reaching R^2_{aj} above 0.70 in most of the cases. Yet, the use of those estimative equations using the detected trees from the TreeDetect tool presented very good results, with maximum error of 9.09% of total stand volume. Considering the above evidences, it is visible that UAV data can be applied with success for individual tree detection and subsequent prediction of dendrometric variables.

Keywords: Drone. Individual tree. Detection. LiDAR. Multiple regression.

LISTA DE FIGURAS

FIGURA 1 - ETAPAS DO PROCESSO DE COLETA DE DADOS COM VANT	53
FIGURA 2 - PROCESSAMENTO DE IMAGENS OBTIDAS POR VANT	59
FIGURA 3 - LOCALIZAÇÃO DOS TALHÕES SELECIONADOS PARA O ESTUDO, NO MUNICÍPIO DE TELÊMACO BORBA, PR.....	74
FIGURA 4 - DETALHES DOS ESTRAGOS CAUSADOS PELOS ATAQUES DE MACACOS E VESPA DA MADEIRA NO TALHÃO <i>PINUS</i> 1	76
FIGURA 5 - VANT UTILIZADO NO LEVANTAMENTO AÉREO	79
FIGURA 6 - DETALHES DO SISTEMA VANT	79
FIGURA 7 - CÂMERAS UTILIZADAS NOS TALHÕES SELECIONADOS PARA O ESTUDO	80
FIGURA 8 - BANDAS ESPECTRAIS PRESENTES NAS CÂMERAS NIR E MULTIESPECTRAL	80
FIGURA 9 - EXEMPLO DE PLANOS DE VOO EXECUTADOS	81
FIGURA 10 - CALIBRAÇÃO RADIOMÉTRICA DA CÂMERA MULTIESPECTRAL ..	83
FIGURA 11 - COLETA E DEMARCAÇÃO DOS PONTOS DE CONTROLE.....	84
FIGURA 12 - MATRIZES DE TRANSFORMAÇÃO UTILIZADAS NO ALINHAMENTO DAS NUVENS DE PONTOS.....	88
FIGURA 13 - ETAPAS DO PROCESSAMENTO DAS NUVENS LIDAR E VANT	89
FIGURA 14 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA NIR PARA O TALHÃO <i>EUCALYPTUS</i>	91
FIGURA 15 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA MULTIESPECTRAL PARA O TALHÃO <i>EUCALYPTUS</i>	91
FIGURA 16 - MDE GERADOS COM AS FOTOGRAFIAS TOMADAS COM AS CÂMERAS NIR E MULTIESPECTRAL PARA O TALHÃO <i>EUCALYPTUS</i> , COM DETALHES DOS MDS E MDT OBTIDOS POR LIDAR	93
FIGURA 17 - ANÁLISE VISUAL DA QUALIDADE DO POSICIONAMENTO DOS ORTOMOSAICOS NOS PONTOS DE CONTROLE, PARA O TALHÃO <i>EUCALYPTUS</i>	93
FIGURA 18 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA RGB PARA O TALHÃO <i>PINUS</i> 1	95

FIGURA 19 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA NIR PARA O TALHÃO <i>PINUS</i> 1.....	95
FIGURA 20 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA MULTIESPECTRAL PARA O TALHÃO <i>PINUS</i> 1.....	96
FIGURA 21 - MDS GERADOS COM AS FOTOGRAFIAS TOMADAS COM AS CÂMERAS RGB, NIR E MULTIESPECTRAL PARA O TALHÃO <i>PINUS</i> 1 COM DETALHES DOS MDS E MDT OBTIDOS POR LIDAR.....	97
FIGURA 22 - ANÁLISE VISUAL DA QUALIDADE DO POSICIONAMENTO DOS ORTOMOSAICOS EM RELAÇÃO AOS PONTOS DE CONTROLE PARA O TALHÃO <i>PINUS</i> 1	97
FIGURA 23 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA RGB PARA O TALHÃO <i>PINUS</i> 2.....	99
FIGURA 24 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA NIR PARA O TALHÃO <i>PINUS</i> 2.....	99
FIGURA 25 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA MULTIESPECTRAL PARA O TALHÃO <i>PINUS</i> 2.....	100
FIGURA 26 - MDS GERADOS COM AS FOTOGRAFIAS TOMADAS COM AS CÂMERAS RGB, NIR E MULTIESPECTRAL PARA O TALHÃO <i>PINUS</i> 2.....	100
FIGURA 27 - ANÁLISE VISUAL DA QUALIDADE DO POSICIONAMENTO DOS ORTOMOSAICOS PARA OS PONTOS DE CONTROLE, NO TALHÃO <i>PINUS</i> 2	102
FIGURA 28 - RELAÇÃO ENTRE ALTURA E DAP E DISTRIBUIÇÕES DESSAS VARIÁVEIS PARA OS TALHÕES <i>EUCALYPTUS</i> , <i>PINUS</i> 1 E <i>PINUS</i> 2.....	103
FIGURA 29 - PARÂMETROS DE ENTRADA DA FERRAMENTA TREEDETECT .	116
FIGURA 30 - DISTINÇÃO DAS CLASSES NA CLASSIFICAÇÃO EXECUTADA NO ECOGNITION	123
FIGURA 31 - DETECÇÃO DE ÁRVORES NAS PARCELAS DO TALHÃO <i>EUCALYPTUS</i>	130
FIGURA 32 - DETECÇÃO DE ÁRVORES NAS PARCELAS DO TALHÃO <i>PINUS</i> 1	133
FIGURA 33 - DETECÇÃO DE ÁRVORES NAS PARCELAS DO TALHÃO <i>PINUS</i> 2	136

FIGURA 34 - EXEMPLOS DE DELIMITAÇÃO DE COPAS COM O ALGORITMO FORESTCAS	149
FIGURA 35 - DIVISÃO DOS DADOS EM CLASSES DE TAMANHO	156
FIGURA 36 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE DAP NO TALHÃO <i>EUCALYPTUS</i> , PARA DADOS DE TREINO E VALIDAÇÃO.....	160
FIGURA 37 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA NO TALHÃO <i>EUCALYPTUS</i> , PARA DADOS DE TREINO E VALIDAÇÃO	163
FIGURA 38 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME NO TALHÃO <i>EUCALYPTUS</i> , PARA DADOS DE TREINO E VALIDAÇÃO	165
FIGURA 39 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE DAP NO TALHÃO <i>PINUS</i> 1, PARA DADOS DE TREINO E VALIDAÇÃO.....	168
FIGURA 40 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA NO TALHÃO <i>PINUS</i> 1, PARA DADOS DE TREINO E VALIDAÇÃO.....	171
FIGURA 41 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME NO TALHÃO <i>PINUS</i> 1, PARA DADOS DE TREINO E VALIDAÇÃO.....	174
FIGURA 42 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE DAP NO TALHÃO <i>PINUS</i> 2, PARA DADOS DE TREINO E VALIDAÇÃO.....	177
FIGURA 43 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA NO TALHÃO <i>PINUS</i> 2, PARA DADOS DE TREINO E VALIDAÇÃO.....	180
FIGURA 44 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME NO TALHÃO <i>PINUS</i> 2, PARA DADOS DE TREINO E VALIDAÇÃO.....	183
FIGURA 45 - ANÁLISE DE RESÍDUO AS EQUAÇÕES ESTIMATIVAS PARA DAP, ALTURA E VOLUME COM A INCLUSÃO DO FATOR DE CORREÇÃO PARA O TALHÃO <i>EUCALYPTUS</i>	185

FIGURA 46 - ANÁLISE DE RESÍDUO DAS EQUAÇÕES ESTIMATIVAS PARA DAP, ALTURA E VOLUME COM A INCLUSÃO DO FATOR DE CORREÇÃO, PARA O TALHÃO <i>PINUS</i> 1	187
FIGURA 47 - ANÁLISE DE RESÍDUO DAS EQUAÇÕES ESTIMATIVAS PARA DAP, ALTURA E VOLUME COM A INCLUSÃO DO FATOR DE CORREÇÃO, PARA O TALHÃO <i>PINUS</i> 2	188

LISTA DE TABELAS

TABELA 1 - PRINCIPAIS TÉCNICAS DE SENSORIAMENTO REMOTO APLICADAS AO MANEJO FLORESTAL	31
TABELA 2 - ASPECTOS DA APLICAÇÃO DE DIFERENTES TIPOS DE VANT EXISTENTES.....	45
TABELA 3 - REQUERIMENTOS DA RBAC-E 94/2017 DA ANAC PARA A OPERAÇÃO DE VEÍCULOS AÉREOS NÃO TRIPULADOS NO BRASIL	49
TABELA 4 - REGULAMENTAÇÃO DECEA PARA ACESSO AO ESPAÇO AÉREO BRASILEIRO.....	52
TABELA 5 - VANTAGENS DA UTILIZAÇÃO DE VANTS PARA SENSORIAMENTO REMOTO	65
TABELA 6 - LIMITAÇÕES DA UTILIZAÇÃO DE VANTS PARA SENSORIAMENTO REMOTO	66
TABELA 7 - ESTADO DA ARTE DE TRABALHOS UTILIZANDO VANTS PARA ESTIMATIVA DE PARÂMETROS ESTRUTURAIS DE FLORESTAS.....	68
TABELA 8 - CARACTERÍSTICAS DOS TALHÕES SELECIONADOS EM TELÊMACO BORBA	75
TABELA 9 - INFORMAÇÕES ADICIONAIS SOBRE O VANT EBEE.....	79
TABELA 10 - ESPECIFICAÇÕES DAS CÂMERAS UTILIZADAS NOS TALHÕES SELECIONADOS PARA O ESTUDO	80
TABELA 11 - RESUMO DAS INFORMAÇÕES AÉREAS COLETADAS.....	83
TABELA 12 - COORDENADAS E PRECISÕES DOS PONTOS DE CONTROLE....	85
TABELA 13 - PROCESSO DE ALINHAMENTO DAS NUVENS DE PONTOS	88
TABELA 14 - ESTATÍSTICAS GERAIS DOS PROCESSAMENTOS DO TALHÃO <i>EUCALYPTUS</i>	90
TABELA 15 - ERROS DO AJUSTAMENTO DAS CÂMERAS NIR E MULTIESPECTRAL, DADOS PELOS PONTOS DE CONTROLE, PARA O TALHÃO <i>EUCALYPTUS</i>	92
TABELA 16 - RESUMO DAS NUVENS DE PONTO VANT E LIDAR UTILIZADAS PARA O TALHÃO <i>EUCALYPTUS</i>	92

TABELA 17 - COMPARAÇÃO ENTRE OS VALORES Z OBTIDOS PARA CADA PONTO DE CONTROLE NOS MDE OBTIDOS POR LIDAR E VANT, PARA OS VOOS REALIZADOS NO TALHÃO <i>EUCALYPTUS</i>	92
TABELA 18 - ESTATÍSTICAS DO AJUSTAMENTO DAS FOTOGRAFIAS AÉREAS COLETADAS PARA O TALHÃO <i>PINUS</i> 1, COM AS CÂMERAS RGB, NIR E MULTIESPECTRAL.....	94
TABELA 19 - ERROS DO AJUSTAMENTO DAS CÂMERAS RGB, NIR E MULTIESPECTRAL, DADOS PELOS PONTOS DE CONTROLE, PARA O TALHÃO <i>PINUS</i> 1	94
TABELA 20 - RESUMO DAS NUVENS VANT E LIDAR UTILIZADAS PARA O TALHÃO <i>PINUS</i> 1	96
TABELA 21 - COMPARAÇÃO ENTRE OS VALORES Z OBTIDOS NOS MDE LIDAR E VANT EM RELAÇÃO AO MDS NIR (REFERÊNCIA), PARA OS VOOS REALIZADOS EM JUNHO NO TALHÃO <i>PINUS</i> 1	98
TABELA 22 - COMPARAÇÃO ENTRE OS VALORES Z OBTIDOS PARA CADA PONTO DE CONTROLE NOS MDE OBTIDOS POR LIDAR E VANT, PARA OS VOOS REALIZADOS EM SETEMBRO NO TALHÃO <i>PINUS</i> 1	98
TABELA 23 - ESTATÍSTICAS DO PROCESSAMENTO COM AS CÂMERAS RGB, NIR E MULTIESPECTRAL PARA O TALHÃO <i>PINUS</i> 2.....	99
TABELA 24 - RESUMO DAS NUVENS VANT E LIDAR UTILIZADAS PARA O TALHÃO <i>PINUS</i> 2.....	101
TABELA 25 - PRECISÃO DO POSICIONAMENTO DOS ORTOMOSAICOS GERADOS COM AS CÂMERAS RGB E NIR PARA O TALHÃO <i>PINUS</i> 2.....	101
TABELA 26 - COMPARAÇÃO ENTRE OS VALORES Z OBTIDOS PARA CADA PONTO DE CONTROLE NOS MDE OBTIDOS POR LIDAR E VANT, PARA OS VOOS REALIZADOS NO TALHÃO <i>PINUS</i> 2.....	101
TABELA 27 - ESTATÍSTICAS DESCRITIVAS DOS DADOS COLETADOS NO CENSO	102
TABELA 28 - SUMÁRIO DOS PARÂMETROS DA FERRAMENTA TREEDETECT	118
TABELA 29 - FERRAMENTAS UTILIZADAS NO CONTEXTO DA FERRAMENTA TREEDETECT	118

TABELA 30 - SUMÁRIO DOS MÉTODOS DE DETECÇÃO TESTADOS	120
TABELA 31 - PARÂMETROS DA FERRAMENTA TREEDETECT UTILIZADOS PARA A DETECÇÃO DE ÁRVORES	121
TABELA 32 - PARÂMETROS DA SEGMENTAÇÃO MULTIRESOLUÇÃO.....	122
TABELA 33 - PARÂMETROS UTILIZADOS NO rLiDAR PARA DETECÇÃO DAS ÁRVORES.....	124
TABELA 34 - RESULTADOS DA DETECÇÃO DE ÁRVORES PELOS DIFERENTES MÉTODOS NO TALHÃO <i>EUCALYPTUS</i>	127
TABELA 35 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM A FERRAMENTA TREEDETECT NO TALHÃO <i>EUCALYPTUS</i>	128
TABELA 36 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM OUTROS MÉTODOS PARA O TALHÃO <i>EUCALYPTUS</i>	128
TABELA 37 - RESULTADOS DA DETECÇÃO DE ÁRVORES PELOS DIFERENTES MÉTODOS NO TALHÃO <i>PINUS</i> 1	131
TABELA 38 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM A FERRAMENTA TREEDETECT NO TALHÃO <i>PINUS</i> 1	132
TABELA 39 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM OUTROS MÉTODOS PARA O TALHÃO <i>PINUS</i> 1	132
TABELA 40 - RESULTADOS DA DETECÇÃO DE ÁRVORES PELOS DIFERENTES MÉTODOS NO TALHÃO <i>PINUS</i> 2	134
TABELA 41 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM A FERRAMENTA TREEDETECT NO TALHÃO <i>PINUS</i> 2	135
TABELA 42 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM OUTROS MÉTODOS PARA O TALHÃO <i>PINUS</i> 2	135
TABELA 43 – RESULTADO GERAL DA DETECÇÃO DE ÁRVORES COM TODOS OS MÉTODOS TESTADOS NOS TRÊS TALHÕES.....	137
TABELA 44 – RANQUEAMENTO DA QUALIDADE DE DETECÇÃO DOS MÉTODOS TESTADOS NOS TRÊS TALHÕES.....	137
TABELA 45 - VARIÁVEIS ESTRUTURAIS E ESPECTRAIS UTILIZADAS NAS ESTIMATIVAS	150
TABELA 46 - VARIÁVEIS DE TEXTURA RELACIONADAS AOS ARQUIVOS ESTRUTURAIS UTILIZADAS NAS ESTIMATIVAS	152
TABELA 47 - VARIÁVEIS DE TEXTURA RELACIONADAS AOS ARQUIVOS ESPECTRAIS UTILIZADAS NAS ESTIMATIVAS.....	153

TABELA 48 - CENÁRIOS DE EQUAÇÕES GERADAS PARA AS ESTIMATIVAS DE DAP, ALTURA E VOLUME	154
TABELA 49 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO <i>EUCALYPTUS</i>	159
TABELA 50 – MELHORES EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO <i>EUCALYPTUS</i>	159
TABELA 51 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO <i>EUCALYPTUS</i>	161
TABELA 52 – MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO <i>EUCALYPTUS</i>	162
TABELA 53 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO <i>EUCALYPTUS</i>	164
TABELA 54 - MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO <i>EUCALYPTUS</i>	164
TABELA 55 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO <i>PINUS</i> 1	166
TABELA 56 - MELHORES EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO <i>PINUS</i> 1	167
TABELA 57 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO <i>PINUS</i> 1	169
TABELA 58 - MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO <i>PINUS</i> 1	170
TABELA 59 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO <i>PINUS</i> 1	172
TABELA 60 - MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO <i>PINUS</i> 1	173
TABELA 61 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO <i>PINUS</i> 2	175
TABELA 62 - MELHORES EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO <i>PINUS</i> 2	176
TABELA 63 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO <i>PINUS</i> 2	178
TABELA 64 - MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO <i>PINUS</i> 2	179

TABELA 65 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO <i>PINUS</i> 2	181
TABELA 66 - MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO <i>PINUS</i> 2.....	182
TABELA 67 – LIMITES DE CLASSES E FATORES DE CORREÇÃO PARA DAP, ALTURA E VOLUME OBSERVADOS NO TALHÃO <i>EUCALYPTUS</i>	184
TABELA 68 – COMPARATIVO DA ESTIMATIVA DE DAP, ALTURA E VOLUME COM E SEM A INCLUSÃO DE FATOR DE CORREÇÃO NO TALHÃO <i>EUCALYPTUS</i>	184
TABELA 69 – LIMITES DE CLASSES E FATORES DE CORREÇÃO PARA DAP, ALTURA E VOLUME OBSERVADOS NO TALHÃO <i>PINUS</i> 1	186
TABELA 70 – COMPARATIVO DA ESTIMATIVA DE DAP, ALTURA E VOLUME COM E SEM A INCLUSÃO DE FATOR DE CORREÇÃO NO TALHÃO <i>PINUS</i> 1	186
TABELA 71 – LIMITES DE CLASSES E FATORES DE CORREÇÃO PARA DAP, ALTURA E VOLUME OBSERVADOS NO TALHÃO <i>PINUS</i> 2	187
TABELA 72 – COMPARATIVO DA ESTIMATIVA DE DAP, ALTURA E VOLUME COM E SEM A INCLUSÃO DE FATOR DE CORREÇÃO NO TALHÃO <i>PINUS</i> 2	188
TABELA 73 - ESTIMATIVA DE VOLUME TOTAL DO TALHÃO <i>EUCALYPTUS</i> COM BASE NAS ÁRVORES DETECTADAS EM COMPARAÇÃO COM O VOLUME OBTIDO NO CENSO	189
TABELA 74 - ESTIMATIVA DE VOLUME TOTAL DO TALHÃO <i>PINUS</i> 1 COM BASE NAS ÁRVORES DETECTADAS EM COMPARAÇÃO COM O VOLUME OBTIDO NO CENSO	189
TABELA 75 - ESTIMATIVA DE VOLUME TOTAL DO TALHÃO <i>PINUS</i> 2 COM BASE NAS ÁRVORES DETECTADAS EM COMPARAÇÃO COM O VOLUME OBTIDO NO CENSO	190

LISTA DE SIGLAS

ALS	– <i>Airborne Laser Scanning</i> (<i>Laser scanner</i> aéreo)
ANAC	– Agência Nacional de Aviação Civil
ANATEL	– Agência Nacional de Telecomunicações
BA	– <i>Bundle Adjustment</i> (aerotriangulação por feixes de raio)
BVLOS	– <i>Beyond Visual Line of Sight</i> (além da linha de visada)
cap	– Circunferência à Altura do Peito (1,3 m)
CHM	– <i>Canopy Height Model</i> (Modelo de altura de copa)
CMA	– Certificado Médico Aeronáutico
CMVS	– <i>Clustering Views for Multi-view Stereo</i>
dap	– Diâmetro à Altura do Peito (1,3 m)
DECEA	– Departamento de Controle do Espaço Aéreo
EVI	– <i>Enhanced Vegetation Index</i> (Índice de Vegetação Melhorado)
EVLOS	– <i>Extended Visual Line of Sight</i> (linha de visada estendida)
FAA	– <i>Federal Aviation Administration</i>
FC	– Fator de correção
FN	– Falso Negativo
FP	– Falso Positivo
GCP	– <i>Ground Control Point</i> (Ponto de controle no solo)
GLCM	– Matriz de co-ocorrência de níveis de cinza
GNSS	– Sistema de Navegação Global por Satélite
GPS	– Sistema de Posicionamento Global
GSD	– <i>Ground Sampling Distance</i> (escala no solo)
IBGE	– Instituto Brasileiro de Geografia e Estatística
IDW	– Ponderação pelo Inverso da Distância
IMU	– <i>Inertial Measurement Unit</i> (unidade de mensuração inercial)
IPARDES	– Instituto Paranaense de Desenvolvimento Econômico e Social
ITCG	– Instituto de Terras, Cartografia e Geologia do Paraná
LiDAR	– <i>Light Detection and Ranging</i>
MD	– Ministério da Defesa
MDE	– Modelo Digital de Elevação
MDS	– Modelo Digital de Superfície

MDT	– Modelo Digital do Terreno
MVS	– <i>Multi View Stereo</i>
NDRE	– Índice de Diferença Normalizada Red-edge
NDVI	– Índice de Vegetação por Diferença Normalizada
NIR	– <i>Near Infrared</i> (Infravermelho próximo)
NN	– <i>Nearest Neighbor</i> (Vizinho mais próximo)
NOTAM	– <i>Notice to Airmen</i> (informação ao aeronavegante)
OBIA	– Análise de Imagem Orientada a Objeto
$R^2_{aj.}$	– Coeficiente de determinação ajustado
RGB	– Red, Green and Blue (Vermelho, verde e azul)
RMSE	– Raiz do Erro Quadrático Médio
RPA	– Aeronave Remotamente Pilotada
RPAS	– Sistema de Aeronave Remotamente Pilotada
RTK	– <i>Real Time Kinematic</i> (Posicionamento Cinemático em Tempo-Real)
SAR	– Radar de abertura sintética
SARPAS	– Sistema de Autorização para Acesso ao Espaço Aéreo por RPAS
SfM	– <i>Structure from Motion</i>
SIFT	– <i>Scale-invariant feature transform</i>
SISANT	– Sistema de Aeronaves não Tripuladas
SR	– Sensoriamento Remoto
SRTM	– Missão Topográfica Radar Shuttle
$S_{yx}\%$	– Erro padrão da estimativa relativo
TLS	– <i>Terrestrial Laser Scanning</i> (<i>Laser scanner</i> terrestre)
TS	– <i>Total station</i> (Estação total)
UAV	– Unmanned Aerial Vehicle
UTM	– Universal Transversa de Mercator
VANT	– Veículo Aéreo Não Tripulado
VLOS	– <i>Visual Line of Sight</i> (linha de visada visual)
VP	– Verdadeiro Positivo
WGS 84	– World Geodetic System (Sistema Geodésico Global) 1984

LISTA DE ABREVIATURAS

2m.	– segundo momento
con.	– contraste
dif.	– diferença numérica
dis.	– dissimilaridade
ent.	– entropia
F calc.	– Valor da estatística F calculado
F tab.	– Valor de F tabelado
gre.	– banda verde
hom.	– homogeneidade
max.	– máximo
med.	– média
N	– número
ns	– não significativo
parc.	– parcela
RE	– banda Red-edge
stdv.	– desvio padrão
sum.	– soma
text.	– textura
var.	– variância
vol.	– volume

SUMÁRIO

CAPÍTULO 1: ASPECTOS GERAIS	22
1.1 INTRODUÇÃO GERAL	22
1.2 REVISÃO BIBLIOGRÁFICA	24
1.2.1 Inventários Florestais	24
1.2.1.1 Introdução e Objetivos	24
1.2.1.2 Tipos e características	24
1.2.1.3 Amostragem e métodos de amostragem	25
1.2.1.4 Principais variáveis amostradas	27
1.2.1.5 Limitações dos inventários florestais tradicionais	29
1.2.2 Sensoriamento Remoto Aplicado à Engenharia e Manejo Florestal	31
1.2.2.1 Imagens de satélite	32
1.2.2.2 <i>Laser Scanners</i>	33
1.2.2.3 Fotogrametria moderna	38
1.2.3 Veículos Aéreos Não Tripulados (VANT)	42
1.2.3.1 Definições e contexto	42
1.2.3.2 Componentes básicos	43
1.2.3.3 Classificação e modelos existentes	44
1.2.3.4 Câmeras e outros sensores remotos	45
1.2.3.5 Legislação do uso de VANTs no Brasil	47
1.2.3.6 Aquisição de dados por meio de VANT	53
1.2.3.6.1 Seleção de equipamento	54
1.2.3.6.2 Planejamento de voo	55
1.2.3.6.3 Processamento de dados: imagens	58
1.2.3.6.4 Aplicativos computacionais	62
1.2.3.7 Vantagens e limitações	64
1.2.3.8 Estado da arte do uso de VANTs em aplicações florestais	67
CAPÍTULO 2: PROCESSAMENTO DE DADOS OBTIDOS POR VANT PARA SUBSIDIAR INVENTÁRIO FLORESTAL	70
2.1 INTRODUÇÃO	70
2.2 OBJETIVOS	73
2.3 MATERIAL E MÉTODOS	73
2.3.1 Área de estudo	73

2.3.2 Características dos talhões selecionados	75
2.3.3 Mensuração e caracterização dos talhões em campo	77
2.3.4 Sistema VANT utilizado.....	78
2.3.5 Coleta de dados VANT	81
2.3.6 Coleta dos pontos de controle.....	84
2.3.7 Processamento das imagens	85
2.3.8 Dados LiDAR.....	86
2.3.9 Análise da qualidade	89
2.4 RESULTADOS	90
2.4.1 Dados proveniente do VANT.....	90
2.4.1.1 Talhão <i>Eucalyptus</i>	90
2.4.1.2 Talhão <i>Pinus</i> 1.....	93
2.4.1.3 Talhão <i>Pinus</i> 2.....	98
2.4.2 Censo Florestal	102
2.5 DISCUSSÃO	104
2.5.1 Dados VANT	104
2.5.2 Caracterização dos talhões	108
2.6 CONCLUSÕES	109
CAPÍTULO 3: DETECÇÃO AUTOMÁTICA DE ÁRVORES A PARTIR DE IMAGENS OBTIDAS POR MEIO DE VEÍCULO AÉREO NÃO TRIPULADO	110
3.1 INTRODUÇÃO	110
3.2 OBJETIVOS	113
3.3 MATERIAL E MÉTODOS.....	113
3.3.1 Área de estudo	114
3.3.2 Material.....	114
3.3.3 Métodos para detecção automática de árvores.....	115
3.3.4 Desenvolvimento da ferramenta TreeDetect	115
3.3.4.1 Definição de parâmetros.....	115
3.3.4.2 Execução	118
3.3.5 Algoritmos aplicados para a detecção.....	120
3.3.5.1 TreeDetect.....	121
3.3.5.2 eCognition	121
3.3.5.3 rLiDAR.....	123
3.3.5.4 PointcloudITD	124

3.3.6 Análise da qualidade	125
3.4 RESULTADOS	127
3.5 DISCUSSÃO	137
3.6 CONCLUSÕES	143
CAPÍTULO 4: ESTIMATIVA DE VARIÁVEIS DENDROMÉTRICAS DERIVADAS DE IMAGENS OBTIDAS POR MEIO DE SENSORES PASSIVOS EMBARCADOS EM VEÍCULO AÉREO NÃO TRIPULADO	144
4.1 INTRODUÇÃO	144
4.2 OBJETIVOS	146
4.3 MATERIAL E MÉTODOS	146
4.3.1 Área de estudo e base de dados.....	146
4.3.2 Delimitação das copas individuais.....	148
4.3.3 Obtenção de variáveis para os modelos estimativos	149
4.3.4 Ajuste das equações e análise de qualidade	153
4.3.5 Inclusão de fator de correção nas equações preditivas	156
4.3.6 Estimativa de volume total com base em árvores detectadas.....	157
4.4 RESULTADOS	158
4.4.1 Estimativas para o talhão <i>Eucalyptus</i>	158
4.4.2 Estimativas para o talhão <i>Pinus</i> 1	165
4.4.3 Estimativas para o talhão <i>Pinus</i> 2	175
4.4.4 Inclusão de fator de correção nas equações estimativas	184
4.4.5 Estimativa do volume total a partir de árvores detectadas automaticamente.	189
4.5 DISCUSSÃO	190
4.6 CONCLUSÕES	196
CONCLUSÃO GERAL E RECOMENDAÇÕES.....	198
REFERÊNCIAS.....	200
APÊNDICE 1 – CORRELAÇÕES ENTRE VARIÁVEIS.....	222
APÊNDICE 2 – EQUAÇÕES DE DAP, ALTURA E VOLUME.....	230

CAPÍTULO 1: ASPECTOS GERAIS

1.1 INTRODUÇÃO GERAL

O inventário florestal tem uma alta importância para o manejo de florestas, pois se configura como a principal fonte de informações sobre os recursos de uma determinada área (PÉLLICO NETTO; BRENA, 1997). Dada a grandeza das áreas florestais, é impraticável a mensuração de todas as árvores e, portanto, é comum a utilização de técnicas de amostragem, nas quais são obtidas informações de parte da população, para estimativa do todo (WEST, 2015). Apesar das técnicas de amostragem, o custo do inventário é considerado grande, principalmente quando se fixam limites de erro rigorosos, que requerem uma amostragem mais intensa. Dados os custos, é comum que apenas algumas variáveis sejam coletadas nas parcelas de forma completa, e outras sejam estimadas a partir de relações matemáticas e da mensuração de apenas alguns indivíduos, como alturas e volumes (SANQUETTA et al., 2014). A aplicação dessas relações, porém, também acarreta em erros de estimativa.

Além do uso de técnicas tradicionais de inventário com base em amostragem em campo, é também comum o uso combinado de dados providos de sensoriamento remoto (KERSHAW JR. et al., 2017; SANQUETTA et al., 2014; WEST, 2015). Esses dados podem ser utilizados em diversas aplicações relacionadas ao inventário e manejo florestal, incluindo mapeamentos e delimitações de áreas, estratificação, obtenção de variáveis para modelos estimativos, e até mesmo a mensuração de variáveis biométricas sem necessidade ou redução de atividades em campo (KERSHAW JR. et al., 2017; WEST, 2015). Dentro dos sensores e técnicas de sensoriamento remoto, pode-se destacar o uso de fotografias aéreas, imagens de satélites, *Laser* (aéreo e terrestre), radares, e mais recentemente o uso de veículos aéreos não tripulados (VANTs) com câmeras embarcadas (HYPPÄ et al., 2015; SANQUETTA et al., 2014; WHITE et al., 2016).

As aplicações dos dados de sensoriamento remoto, porém, dependem da tecnologia aplicada, sendo que normalmente informações mais detalhadas requerem resoluções altas, que em muitos casos não são disponíveis ou tem custo elevado (SANQUETTA et al., 2014). Nesse contexto, umas das mais promissoras técnicas que emergiu nos últimos anos foi a aplicação de fotografias capturadas a partir de VANT,

pois essas apresentam vantagens, como a capacidade de aquisição de dados com alta resolução e com custos reduzidos em relação a outros sensores remotos (PÁDUA et al., 2017; WHITEHEAD et al., 2014). Dadas essas características, diversos estudos tem apresentado o uso de VANTs em aplicações florestais, que compreendem tanto classificações, como obtenção de variáveis estruturais, de diversidade, monitoramentos, entre outros (PÁDUA et al., 2017; TORRESAN et al., 2017). Apesar disso, a gama de sensores e veículos aéreos é muito grande e, portanto, é difícil generalizar os resultados visto que cada sistema apresenta particularidades. Além disso, poucos estudos são encontrados até o momento com foco em florestas plantadas, principalmente em regiões tropicais. Dentro desse contexto, nesse estudo foi avaliada a possibilidade da utilização de fotografias obtidas com uso de VANT para aplicações em inventário florestal, com foco em plantios florestais comerciais de *Pinus* e *Eucalyptus*.

O trabalho foi organizado em seis capítulos, sendo que nesses são abordados:

- Capítulo 1: introdução geral, revisão bibliográfica e contextualização;
- Capítulo 2: descrição da área de estudo, do levantamento de dados em campo, e da coleta de dados com VANT, assim como a avaliação dos produtos obtidos a partir dessas etapas;
- Capítulo 3: apresentação de uma ferramenta desenvolvida para a detecção automática de árvores em dados provenientes de VANT;
- Capítulo 4: apresentação de metodologia para obtenção de dap, altura e volumes a partir de dados provenientes de VANT;
- Conclusão geral e recomendações para estudos futuros.

A partir deste trabalho espera-se obter informações que deem suporte para o uso de VANT em aplicações florestais de áreas plantadas, e norteiem rumos que podem ser desenvolvidos em pesquisas futuras.

1.2 REVISÃO BIBLIOGRÁFICA

1.2.1 Inventários Florestais

1.2.1.1 Introdução e Objetivos

Segundo a definição de Péllico Netto e Brena (1997), inventário florestal é uma atividade que visa obter informações qualitativas e quantitativas dos recursos florestais existentes em uma área pré-especificada. Segundo Sanquetta et al. (2014), um importante ponto que caracteriza um inventário florestal, e o diferencia de simples levantamentos, é a representatividade amostral e validade estatística que este apresenta.

Dessa forma, os inventários florestais são atividades nas quais o manejador florestal consegue as necessárias informações para a tomada de decisões e o planejamento futuro da uma determinada atividade florestal (PÉLLICO NETTO; BRENA, 1997). Além do manejo produtivo do povoamento em si, os inventários podem servir como base para o manejo sustentado integrado da floresta, e de planos de desenvolvimento e política florestal de caráter regional ou nacional (KERSHAW JR. et al., 2017). De maneira geral, as aplicabilidades de um inventário dependem do seu objetivo e, conseqüentemente, das informações coletadas.

1.2.1.2 Tipos e características

Segundo Péllico Netto e Brena (1997), os inventários florestais podem ser discriminados de acordo com cinco principais variáveis, sendo elas: objetivos, normalmente tático ou estratégico (setor público); abrangência, sendo nacionais, regionais, ou de áreas restritas (propriedade de uma empresa); obtenção dos dados, que pode ser dado por censo (enumeração total), amostragem, ou tabelas de produção; abordagem da população no tempo, sendo possível única ou múltiplas ocasiões (inventário contínuo); e detalhamento dos resultados, sendo nesse caso variável em função dos dados levantados. Dentre esses parâmetros, um dos mais importantes é a forma de obtenção dos dados, sendo que apesar do censo florestal permitir a obtenção dos parâmetros da população, é uma atividade que exige tempo e apresenta alto custo, sendo justificável apenas em pequenas áreas, em trabalhos

científicos, ou em casos exigidos por legislação (PÉLLICO NETTO; BRENA, 1997; SANQUETTA et al., 2014). Já na técnica de amostragem, realiza-se a mensuração de uma parte da população para a posterior extrapolação dos resultados para o restante da população (LEITE; ANDRADE, 2002).

Apesar dessas classificações, normalmente são considerados alguns tipos principais, sendo eles: inventário de pré-corte, realizado antes da atividade de colheita e com uma intensidade amostral alta; inventário convencional, realizado para determinação de estoques de volume; inventário contínuo, no qual se observam mudanças na floresta; inventários para plano de manejo, realizado com alto grau de detalhamento, em muitos casos obtendo estimativas por classes diamétricas e por espécie; e inventário de sobrevivência, realizado após o plantio para identificação da relação entre falhas e sobrevivência de mudas; inventário para prognose, em que se coletam informações em uma certa idade para estimar parâmetros na idade final da rotação; inventário para desbaste, geralmente executado antes e depois da realização do desbaste para observação das árvores removidas; inventário qualitativo, realizado para avaliar a qualidade do plantio de mudas, realizado geralmente aos 12 meses do plantio; entre outros (SCOLFORO; MELLO, 2006; SOARES; NETO; SOUZA, 2011).

1.2.1.3 Amostragem e métodos de amostragem

A maior parte dos inventários florestais é realizada partindo-se da coleta de informações em parte da população total, ou seja, com base em amostras. A amostragem, por exemplo, consiste na observação de parte de uma população, a partir da qual é possível fazer inferências sobre o todo com certo grau de incerteza (PÉLLICO NETTO; BRENA, 1997; WEST, 2015). A grande vantagem da aplicação da amostragem é a possibilidade de obtenção da informação necessária em um tempo menor, e com menor custo (COCHRAN, 1977; HIGUCHI; SANTOS; JARDIM, 1982).

Para que a amostragem seja representativa da população, alguns parâmetros devem ser considerados, como o método amostral, a intensidade amostral, tamanho e forma das unidades amostrais, a distribuição sobre a área, além do erro amostral e a precisão (HIGUCHI; SANTOS; JARDIM, 1982; PÉLLICO NETTO; BRENA, 1997). A intensidade de amostragem é dada pela relação entre o número de unidades amostrais e o número de unidades da população, ou da área amostrada em relação à área total da população (SANQUETTA et al., 2014). O tamanho da amostra é

calculado em função da variância da população, precisão e confiabilidade desejada, ou do tempo e custo disponíveis (PÉLLICO NETTO; BRENA, 1997). Para a obtenção da estimativa dos parâmetros da população necessários, normalmente média e variância, são utilizados dados de inventários passados, ou pela realização de um inventário piloto (SOARES; NETO; SOUZA, 2011). O número de unidades amostrais, por sua vez, pode ser considerada a relação do tamanho da amostra desejada e da área das unidades amostrais, pois, no geral, quanto maior a área de cada unidade amostral, menor o número de unidades amostrais necessárias, o que pode ser vantajoso em termos de deslocamento (HIGUCHI; SANTOS; JARDIM, 1982). Por outro lado, o uso de um maior número de parcelas pode representar melhor a variação da população (PRODAN, 1968).

Quanto aos processos de amostragem, os principais são: a amostragem aleatória simples, sistemática, estratificada, e por conglomerados (BONHAM, 2013; PÉLLICO NETTO; BRENA, 1997). A amostragem aleatória simples, é o tipo mais simples de amostragem, e parte da divisão da área em unidades amostrais e o sorteio independente de unidades na área (BONHAM, 2013; SOARES; NETO; SOUZA, 2011). A amostragem sistemática parte do sorteio de uma única amostra e da seleção das demais de forma sistemática (SCOLFORO; MELLO, 2006), reduzindo o tempo de deslocamento entre as unidades devido à organização constante (SOARES; NETO; SOUZA, 2011). A amostragem estratificada, por outro lado, parte da divisão da população em áreas com características homogêneas (KERSHAW JR. et al., 2017; WEST, 2015), e o sorteio ou sistematização de unidades nos estratos, geralmente proporcionalmente à área de cada estrato (SCOLFORO; MELLO, 2006). A amostragem estratificada é considerada um dos processos mais eficientes (WEST, 2015), pois com a diminuição da variância dentro dos estratos, pode-se reduzir o número de unidades amostrais e, conseqüentemente, os custos (KERSHAW JR. et al., 2017; PÉLLICO NETTO; BRENA, 1997). Por fim, na amostragem por conglomerados várias pequenas unidades são medidas formando uma unidade maior (KERSHAW JR. et al., 2017), e é normalmente utilizada em inventários de florestas naturais em grandes áreas para reduzir tempo de deslocamento (KERSHAW JR. et al., 2017; LAAR; AKÇA, 2007).

1.2.1.4 Principais variáveis amostradas

Dados os distintos tipos de inventários florestais, é também esperado que distintas variáveis sejam mensuradas em campo. Apesar disso, algumas variáveis, como diâmetro à altura do peito (dap) e altura, são mensuradas em praticamente todos os tipos de inventários. O dap é considerado como a mais importante variável no inventário florestal, é obtido na altura padrão de 1,3 m, permite a obtenção do valor de área basal, e é comumente utilizado para a estimativa de outras variáveis (SOARES; NETO; SOUZA, 2011). A medida do dap pode tanto ser tomada com suta, fita métrica ou medidores óticos (KERSHAW JR. et al., 2017; SANQUETTA et al., 2014). Em nível de talhão, em muitos casos é importante se obter o diâmetro médio, que pode ser expresso pela média aritmética, diâmetro modal, diâmetro quadrático médio, diâmetro as árvores dominantes (maiores daps), entre outros (SANQUETTA et al., 2014).

A altura, por sua vez, é utilizada principalmente para obtenção de informações sobre índice de sítio e volume (LAAR; AKÇA, 2007). A medida de altura mais comum é a total, definida como a distância entre a base e o topo da árvore (LAAR; AKÇA, 2007; SOARES; NETO; SOUZA, 2011). Outras alturas podem também ser tomadas como: altura comercial, dada como a distância a partir da parte sem deformações até o diâmetro comercial da árvore; altura do fuste, dada pela distância entre a base e o início da copa da árvore; e altura da copa, como a distância da base da copa até o topo da árvore (KERSHAW JR. et al., 2017; SANQUETTA et al., 2014).

Segundo Kershaw Jr. et al. (2017), a medição de alturas se dá por hipsômetros, que podem ser baseados nos princípios: geométrico, baseado na relação entre triângulos, como o hipsômetro de Christen; ou trigonométrico, que se baseia em ângulos e distâncias, como o hipsômetro de Haga, o clinômetro de Sunnto, o Vertex, e o hipsômetro eletrônico Haglof. O método geométrico tem a vantagem de não necessitar saber a distância do mensurador até a árvore, porém normalmente apresenta erros elevados em árvore altas, enquanto que o método trigonométrico exige o conhecimento da distância, porém é apropriado para qualquer altura (SOARES; NETO; SOUZA, 2011). Normalmente, os hipsômetros mais utilizados são os baseados na trigonometria (SANQUETTA et al., 2014), e para tanto é comum que se utilize uma distância do operador até a árvore, aproximadamente igual à da árvore que será medida (KERSHAW JR. et al., 2017).

Em nível de parcelas, é comum que se mensure valores de altura como a altura média, que pode ser obtido pela média da altura de todas as árvores, ou pela mensuração de certa proporção de árvores dominantes, ou das árvores mais grossas (KERSHAW JR. et al., 2017), além de outros métodos similares. Nos casos em que nem todas as árvores são medidas quanto à altura, é comum a estimativa das demais alturas pelo ajuste de modelos de regressão com base no dap (LAAR; AKÇA, 2007).

Outros inventários podem exigir a observação de idade e composição de espécies (florestas nativas), volume e/ou biomassa, parâmetros de copa (fechamento, Índice de área foliar – LAI), e dados sobre regeneração (KERSHAW JR. et al., 2017; LAAR; AKÇA, 2007). Dentre esses, para florestas plantadas os mais interessantes são o volume, biomassa e carbono. O volume das árvores normalmente é obtido em função do volume acima do solo, e pode, assim como altura, ser dividido em comercial, do fuste e outros (SOARES; NETO; SOUZA, 2011). O volume pode ser obtido pelo método de deslocamento de massa, porém esse é pouco prático, de forma que normalmente se aplica algum método de cubagem, que parte da derrubada da árvore e medida da área de seções ao longo do fuste, a partir das quais se desenvolvem equações que estimam o volume das árvores a partir de um fator de forma calculado pela relação entre o volume de um cilindro e o volume real da árvore cubada (LAAR; AKÇA, 2007; SOARES; NETO; SOUZA, 2011).

A biomassa, quando o foco é somente no fuste para fins de produção, pode ser obtida pela relação entre o volume e a densidade da madeira, normalmente aplicado em casos de florestas homogêneas com densidade conhecida (KERSHAW JR. et al., 2017). Já quando se objetiva o conhecimento da biomassa acima do solo de forma completa (incluindo folhas, galhos, e possivelmente vegetação rasteira), normalmente para estudos com objetivo de estimativa de carbono, é utilizada a pesagem da biomassa verde dos diversos componentes encontrados em dada parcela definida (SOARES; NETO; SOUZA, 2011), conhecido como método destrutivo. Depois da coleta e pesagem dos componentes em campo, esses são secos e pesados novamente em laboratório, de forma a se obter a biomassa em si (matéria em função de área). Ainda, é possível a obtenção do conteúdo de carbono desde que se realize análise do teor de carbono em parte dessas amostras, ou da aplicação de alguma relação já existente entre biomassa e carbono (KERSHAW JR. et al., 2017). Os valores de biomassa podem também ser obtidos indiretamente, a partir de relações com dap, altura e volume (BONHAM, 2013; LAAR; AKÇA, 2007).

1.2.1.5 Limitações dos inventários florestais tradicionais

De maneira geral, pode-se listar que as limitações dos inventários florestais se relacionam a três tópicos principais: custos, erros e abrangência, apesar de relacionados entre si. Os erros nos dados provindos de inventários florestais tradicionais podem ser oriundos de várias fontes, entre elas erros provindos de equipamentos mal calibrados, dificuldades na correta identificação do objeto, influências do terreno e erro humano (SANQUETTA et al., 2014; SOARES; NETO; SOUZA, 2011). Dado que os inventários são realizados a partir de amostragem, existe também o erro amostral, que está intimamente ligado à intensidade amostral e à seleção de métodos e processo apropriados (PÉLLICO NETTO; BRENA, 1997; SANQUETTA et al., 2014).

Especificamente pode-se apontar erros de medição como a utilização de fitas inclinadas na medição do dap (KERSHAW JR. et al., 2017; SOARES; NETO; SOUZA, 2011), ou oclusões e falhas de posicionamento do operador na medição da altura (KERSHAW JR. et al., 2017). Esses erros são mais pronunciados para as alturas, visto que em florestas densas é difícil identificar com clareza o topo de cada árvore individualmente (KERSHAW JR. et al., 2017). Nesse sentido, segundo Hyypä et al. (2015), as exatidões normalmente esperadas para essas variáveis são de: 0.5-2 m para altura, 5-10 mm para dap, e 10-20% para volume e biomassa.

Outro fato importante a se considerar é que as medidas de dap e altura são comumente utilizadas em equações para estimativa de outras variáveis, como volume, biomassa e carbono. Essas equações, apesar de muito úteis, na maior parte dos casos, são específicas para áreas e espécies, sendo portanto inaplicáveis em larga escala sem calibração com dados de campo (BONHAM, 2013), ou são equações regionais que apresentam elevados erros se aplicadas a talhões específicos (KERSHAW JR. et al., 2017). Quanto aos erros esperados, segundo Sanquetta et al. (2014), as equações de volume normalmente apresentam erro padrão inferior a 10%, enquanto que as equações hipsométricas apresentam erro normalmente abaixo de 25%.

Os custos do inventário e tempo de execução, por sua vez têm alta relação com as variáveis a serem mensuradas, intensidade amostral, limite de erro definido, e características da área (PÉLLICO NETTO; BRENA, 1997; SANQUETTA et al., 2014). Os custos do inventário se compõem de elementos fixos e variáveis, sendo que

os segundos correspondem à etapa de realização propriamente dita e compreendem o número de unidades amostrais, a média de deslocamento entre unidades e o custo médio de medição de cada unidade (PÉLLICO NETTO; BRENA, 1997). Independentemente do tipo de inventário, custos com o pagamento de pessoal, transporte, serviços de terceiros, material de consumo, equipamentos, administração, atividade de campo, entre outros, sempre estão presentes (SANQUETTA et al., 2014). Alguns custos porém podem ser controlados, sendo esses ligados a fatores organizacionais ou técnicos (relativos à variáveis, técnicas de medição, e precisão requerida) (SANQUETTA et al., 2014).

Entre dap e altura, a altura é a que requer maior tempo de medição, visto que exige diversos procedimentos, como a medição da distância da árvore, e a visada da base e do topo da árvore na maioria dos casos (SANQUETTA et al., 2014). Em florestas densas esse procedimento costuma ser ainda mais demorado, devido à dificuldade de identificação do topo das árvores (KERSHAW JR. et al., 2017). Devido a esses custos, é comum que se mensure apenas parte das árvores da parcela e que a altura das demais seja estimada com equações hipsométricas (SANQUETTA et al., 2014), cujos erros foram detalhados anteriormente.

Por fim, é importante destacar que os inventários florestais têm abrangência de certa forma limitada, pois, apesar de se objetivar a amostragem suficiente de toda a área, nem sempre toda ela é avaliada nos inventários, o que causa o chamado erro amostral (SANQUETTA et al., 2014). Conforme já destacado, se aplicada uma intensidade amostral alta, os erros tendem a diminuir, porém o custo é mais elevado (SOARES; NETO; SOUZA, 2011). Comumente são aplicados inventários estratificados (KERSHAW JR. et al., 2017), porém em muitos casos é difícil realizar uma correta estratificação da área pois normalmente existem poucas informações sobre a área no total (SANQUETTA et al., 2014). Dadas essas limitações, é comum o uso de informações geoespacializadas, como dados provindos de sensoriamento remoto, aplicados para tarefas diversas, como planejamentos, estratificação, obtenção de parâmetros florestais, e uso de dados remotos como co-variáveis em modelos estimativos de volume, biomassa ou outros (KERSHAW JR. et al., 2017; SANQUETTA et al., 2014). O uso desse tipo de dado, seja obtido por fotografias aéreas ou imagens de satélite, permitem um mapeamento de forma mais abrangente das áreas de interesse, porém a aplicação desses dados depende de diversos fatores que serão apresentados em tópico específico.

1.2.2 Sensoriamento Remoto Aplicado à Engenharia e Manejo Florestal

São diversas as aplicações de produtos derivados de técnicas de Sensoriamento Remoto na área do manejo florestal, dentre as quais, as mais comuns, assim como os tipos de sensores, estão apresentadas na TABELA 1, e discutidos nos tópicos que se seguem. Os VANTs e suas aplicações não estão incluídos nessa tabela porque serão apresentados de forma detalhada em um tópico específico.

TABELA 1 - PRINCIPAIS TÉCNICAS DE SENSORIAMENTO REMOTO APLICADAS AO MANEJO FLORESTAL

	Tipo	Aplicações	Exemplos
Radiação passiva	Imagem de satélite		
	Baixa e baixíssima resolução ¹	Mapeamentos de grandes áreas florestais.	Terra/Aqua MODIS, SPOT vegetation
	Média resolução	Estimativas de área, idade, altura, biomassa acima do solo e acumulada em nível de talhões.	Landsat, ASTER, CBERS
	Alta e altíssima resolução	Identificação de árvores dominantes, alturas, volume e biomassa em nível de talhão. Identificação de espécies. Detecção de árvores, copas e biomassa.	QuickBird, WorldView IKONOS, SPOT
	Fotogrametria aérea	Mapeamento de áreas florestais por tipo, caracterização de condições da floresta, monitoramento de danos por insetos, doenças e incêndios, monitoramento de produtividade. Obtenção de parâmetros de composição (espécies) e estrutura (altura) da floresta.	Diversas câmeras
Radiação ativa	Laser orbital	Estimativas globais de biomassa. Estimativas de carbono estocado.	GLAS GEDI
	Laser scanner aéreo (ALS)	Caracterização vertical e horizontal da floresta. Estimativas de altura média, volume e correlações com biomassa aérea de talhões. Detecção, estimativas de altura e volume de árvores individuais, identificação de espécies, estimativas de crescimento. Obtenção de modelos detalhados do terreno, aplicado em outras aplicações florestais. Parâmetros ecológicos, como fechamento da copa e distribuição de clareiras.	Fabricantes: TopoSys Harrier Model Range, Leica Geosystems, Riegl, outros
	Laser scanner terrestre (TLS)	Estrutura da floresta como dap e posição das árvores; Estimativa acuradas de volume e biomassa. Modelagem de superfícies com precisão milimétrica.	Fabricantes: FARO, Leica Geosystems, Trimble, outros

FONTE: adaptado de: imagem de satélite (HELMER et al., 2015; WHITE et al., 2016); fotogrametria aérea (DURRIEU et al., 2015; WHITE et al., 2016); radar (HYPPÄ et al., 2015; KOCH, 2010); Laser orbital (HYPPÄ et al., 2015); ALS (HYPPÄ et al., 2008, 2015; VAUHKONEN et al., 2014); TLS (DASSOT; CONSTANT; FOURNIER, 2011; HYPPÄ et al., 2015; LIANG et al., 2016; VAN LEEUWEN; NIEUWENHUIS, 2010).

¹ Baseada em White et al. (2016) em que se classificam como resoluções: muito baixa, GSD > 1.000 m, baixa GSD de 100 m–1.000 m; média GSD 10 m–100 m; alta GSD 1 m–10 m; e muito alta GSD menor que < 1m.

1.2.2.1 Imagens de satélite

As imagens obtidas por meio satélites orbitais são uma das principais fontes de dados de sensoriamento remoto para aplicações ambientais e florestais, e apresentam uma gama muito grande de sensores com distintas características (HELMER et al., 2015). De maneira geral, as imagens podem ser caracterizadas pelas resoluções espacial, espectral, temporal e geométrica (JENSEN, 2009), todas relevantes para a definição das aplicações possíveis de determinado sensor. Em termos de aplicabilidade na área florestal, a resolução espacial tem um importante papel, pois delimita a dimensão dos objetos (e consequentemente feições) que podem ser identificadas para cada sensor, dessa forma a caracterização de aplicações devido a esse parâmetro são comuns. Apesar disso, a noção de resolução espacial é variada (WHITE et al., 2016), e nesse caso toma-se como base a classificação: muito baixa > 1.000 m, baixa 100 m–1.000 m; média 10 m–100 m; alta 1 m–10 m; e muito alta < 1m (WHITE et al., 2016), tendo-se em consideração que no trabalho citado não foi feita a diferenciação de classe para o valor limite entre duas classes. Nesse caso, também se foca em satélites com sensores passivos, já que os ativos serão tratados nos tópicos de *Laser scanner* e radar.

De maneira geral, as imagens de resolução baixa ou muito baixa geralmente são utilizadas em aplicações meteorológicas ou para classificações de florestas e formações florestais em escalas globais ou continentais, ou são combinadas com dados históricos e imagens com resolução mais alta (HELMER et al., 2015). Apesar dessas imagens apresentarem baixa resolução espacial, em muitos casos elas apresentam uma taxa de recobrimento alta, pois tem uma cobertura de visada de quilômetros (JENSEN, 2009; PANDA et al., 2015; TOTH; JÓZKÓW, 2016), sendo muito útil em análises que requerem imagens em datas recorrentes. Os satélites de média resolução, como Landsat e CBERS são comumente aplicados em mapeamentos de tipos de vegetação, e em geral apresentam bandas além do visível. Esses satélites apresentam comumente uma banda pancromática com resolução espacial maior que as demais (PANDA et al., 2015; TOTH; JÓZKÓW, 2016), permitindo fusões entre as bandas e aquisição de maiores detalhes nas mesmas bandas espectrais. Já para análises em nível florestal mais específico, como estimativas em nível de talhão, recomendam-se resoluções maiores, acima de 5 m para que seja possível delimitar o tamanho de copas e, em geral, a presença de maior

número de bandas espectrais (HELMER et al., 2015; WHITE et al., 2016). Em resoluções altas e muito altas, geralmente em pequenas faixas do espectro, é possível estimativas de volume, biomassa, altura e fechamento de copa (WHITE et al., 2016).

A resolução espectral, por outro lado, corresponde à capacidade de um sensor de capturar informação em distintas regiões do espectro eletromagnético (PANDA et al., 2015), e é importante porque, quanto maior for o número de bandas cobertas pelo sensor, maior será a capacidade dele de discernir alvos específicos (PANDA et al., 2015). Os sensores com capacidade de imageamento além das bandas do visível são divididos entre multiespectral e hiperespectral, sendo que os primeiros normalmente incorporam ao menos uma faixa na região do infravermelho, e são os mais comuns em aplicações florestais (HELMER et al., 2015), devido à capacidade de observação de padrões florestais na faixa do infravermelho. Ainda, esses sensores são importantes porque, dada a separação das bandas, é possível a realização de diversas composições e combinações, assim como a aplicação de índices de vegetação (PANDA et al., 2015).

De acordo com as características de cada sensor, podem ser necessárias distintas técnicas de processamento para extração das informações de interesse, dentre elas calibrações (geométrica, radiométrica ou espectral), aplicação de técnicas de realce, geração de índices e classificações (NARUMALANI; MERANI, 2015; XIE; SHA; YU, 2008). No âmbito das classificações, essas podem ser não supervisionadas, ou supervisionadas, sendo as últimas as mais aplicadas no âmbito florestal, e incluem diversos métodos, como as classificações por pixel (pelos algoritmos vizinho mais próximo, *maximum likelihood*), baseadas em objetos, a partir de árvores de decisão, redes neurais artificiais, entre outros (NARUMALANI; MERANI, 2015).

1.2.2.2 Laser Scanners

Conforme já apresentado na TABELA 1, os *Laser scanners* podem ser de três tipos principais, sendo eles o do tipo orbital, aéreo (ALS – *Airborne Laser Scanning*), e terrestre (TLS - *Terrestrial Laser Scanning*) (HYYPÄ et al., 2015; KOCH, 2010). Os sensores Laser também são comumente chamados de LiDAR (*Light Detection and Ranging*). A diferença desses tipos de LiDAR está na plataforma que carrega o sensor *laser*, aeronave no caso de ALS e tripé para TLS, porém o princípio de funcionamento deles é bastante similar, sendo a emissão de um pulso de energia, e o cálculo de

distâncias a partir do tempo entre transmissão e recepção da energia de retorno (DALMOLIN; SANTOS, 2004; VAN LEEUWEN; NIEUWENHUIS, 2010). Cada pulso emitido pode registrar um ou diversos retornos (WHITE et al., 2016).

Os sensores ALS apresentam diversos sensores, de vários fabricantes, incluindo os modelos da Leica e Reigel (FAVORSKAYA; JAIN, 2017), e o sistema é composto pelo próprio LiDAR embarcado em uma plataforma aérea, e o sistema de comunicação e posicionamento (GPS/IMU) (FAVORSKAYA; JAIN, 2017). A soma das informações coletadas por todos esses sensores é utilizada de forma conjunta para calcular a posição dos pontos resultantes do levantamento ALS (FAVORSKAYA; JAIN, 2017), que se trata, portanto, de uma nuvem de pontos 3D com informações x, y e z de todos os pontos (HYYPÄ et al., 2015). Essa nuvem de pontos pode ainda conter informações de intensidade, número do retorno e, em alguns tipos de sensores, é capaz de caracterizar o sistema de ondas de forma contínua (sistemas *full-waveform*) (BALDAUF; GARCIA, 2016; HYYPÄ et al., 2015). A maioria dos sistemas ALS utilizados em aplicações florestais é de sensores com retorno discreto e *small footprint* (ou seja, pequena área de varredura) (VAUHKONEN et al., 2014).

Os dados derivados de ALS tem demonstrado grande potencial para modelagem tanto em nível de parcelas quanto em nível de árvores individuais (VAUHKONEN et al., 2014), e normalmente o processamento dos dados se inicia pela filtragem da nuvem de pontos para a classificação dos pontos do solo e geração de um modelo digital do terreno (MDT) (HYYPÄ et al., 2008; VAUHKONEN et al., 2014). Normalmente a filtragem de pontos do solo é realizada com base em algoritmos, podendo-se citar a densificação progressiva TIN, filtros morfológicos, filtros baseados na curvatura, e outros (BALDAUF; GARCIA, 2016; VAN LEEUWEN; NIEUWENHUIS, 2010). Além da seleção de um algoritmo apropriado, a qualidade do MDT depende de características dos dados ALS, como densidade de pontos, altura de voo, ângulo de escaneamento, além de características da área de interesse, como tipo de terreno (declividade por exemplo, presença de mudanças abruptas de elevação), densidade e altura da vegetação e sub-bosque, presença de diferentes tipos de terrenos na mesma área, e outros (FAVORSKAYA; JAIN, 2017). É importante considerar que é necessário realizar uma boa filtragem porque erros no MDT geralmente remetem a erros na mensuração de alturas (HYYPÄ et al., 2008).

Após a geração do MDT, esse é utilizado para a normalização da nuvem de pontos ou geração de um modelo de altura de copa (CHM – *canopy height model*),

normalmente utilizado na detecção de árvores individuais. A normalização da nuvem de pontos se refere à transformação dos valores de altura dos pontos em um determinado sistema de coordenadas, para valores referentes a altura destes em relação ao solo. O CHM é gerado pela diferença entre o modelo digital de superfície (MDS), dado pela interpolação dos pontos mais altos (primeiro retorno do pulso), pelo MDT (HYYPÄ et al., 2008). A partir do CHM, as árvores individuais podem ser detectadas, normalmente utilizando-se de algum algoritmo de *local maxima* (pontos mais altos), segmentação de bacias, ou crescimento de regiões, entre outros (FAVORSKAYA; JAIN, 2017). Um ponto importante que deve ser destacado, é que normalmente não é possível detectar todas as árvores, principalmente em relação às árvores com copas entrelaçadas ou dominadas (VAN LEEUWEN; NIEUWENHUIS, 2010; VAUHKONEN et al., 2014), sendo esse o principal erro dos métodos baseados em árvore individual. O sucesso da detecção depende de vários fatores, como as condições da floresta (densidade e padrão espacial), algoritmos e parâmetros, entre outros (VAUHKONEN et al., 2014).

Dada a detecção das árvores, normalmente busca-se obter o delineamento de copas, baseado em algum tipo de segmentação, detecção de borda, ou algoritmos de *local minima* (HYYPÄ et al., 2008; VAN LEEUWEN; NIEUWENHUIS, 2010). Além do delineamento de copas, normalmente se extrai a altura das árvores detectadas, baseando-se na altura do CHM, porém é comum se observar a subestimativa das alturas (HYYPÄ et al., 2008; VAN LEEUWEN; NIEUWENHUIS, 2010). A subestimativa é explicada pelo fato dos pulsos LiDAR atingirem as laterais da copa com mais probabilidade do que o ponto máximo da copa, especialmente em coníferas (BALDAUF; GARCIA, 2016; HYYPÄ et al., 2008).

Os métodos baseados em área (geralmente em parcelas) apresentam um procedimento um pouco diferente, normalmente tendo como processo básico as etapas de: delimitação da área, execução de inventário em campo, aquisição dos dados ALS e processamento, ajuste de modelo entre dados ALS e campo, e estimação de parâmetros para a área toda (NÆSSET, 2014). O processamento dos dados ALS envolve a divisão dos dados no formato das parcelas de referência de campo, a normalização da nuvem pelo MDT, e a extração de métricas que serão relacionadas com os valores inventariados em campo (NÆSSET, 2014). As métricas utilizadas normalmente se referem às alturas e densidade de copa (HYYPÄ et al., 2008; NÆSSET, 2014), como altura média, percentis de altura (altura da densidade

dos pontos nos percentis de 0 até 99%), coeficiente de variação da altura, no caso de métricas de altura, e a proporção de primeiros e últimos pulsos acima dos percentis (de 0 até 99% dos pulsos) no caso das métricas de densidade (HYYPÄ et al., 2008; WULDER et al., 2012). Essas métricas podem então ser aplicadas em métodos de estimativa paramétricos e não paramétricos para estimativa dos parâmetros de interesse (WULDER et al., 2012).

Os métodos baseados em área são os mais consolidados, e considerados padrão em inventários florestais, permitindo a estimativa de variáveis como altura, volume e área basal de talhões (HYYPÄ et al., 2008; WHITE et al., 2016). Apesar disso, os métodos de árvore individual tem sido bastante aplicado em mais recentes anos e apresentam a vantagem de não necessitar de volume de dados de campo tão extenso como necessário para os métodos de área (devido à necessidade de calibração para cada caso), além de apresentarem boa relação biológica com parâmetros como volume (HYYPÄ et al., 2008). Os métodos de área por outro lado são mais fáceis de integrar ao atual sistema de inventários por parcela aplicados em campo e permitem uma coleta de dados ALS mais econômica (WULDER et al., 2012), pois os métodos de árvore individual exigem densidades altas de pontos (WHITE et al., 2016).

Os sensores TLS começaram a ser utilizados no meio florestal em um período mais recente e são caracterizados por um sensor *Laser* posicionado em um tripé, sendo que esse sistema realiza uma rápida movimentação vertical e uma lenta movimentação horizontal de 180° nas duas direções do instrumento, completando uma visada de 360° (LIANG et al., 2016). O TLS é capaz de detectar níveis de detalhe maiores do que o ALS (VAN LEEUWEN; NIEUWENHUIS, 2010), porém é limitado principalmente pelo seu alcance, principalmente na área florestal devido à oclusão da visada pelas próprias árvores e vegetação de sub-bosque (FAVORSKAYA; JAIN, 2017; VAN LEEUWEN; NIEUWENHUIS, 2010).

Os sensores TLS podem ser aplicados em um único escaneamento, ou em múltiplos escaneamentos, sendo esse segundo o mais comum e acurado em parcelas florestais, dado o curto alcance do TLS e o interesse em obter informações nos diversos ângulos das árvores (DASSOT; CONSTANT; FOURNIER, 2011; LIANG et al., 2016). Nesses casos em que se usam múltiplos escaneamentos, o sensor TLS é mudado de posição e a conexão entre as nuvens de pontos obtidas é feita por meio

de alvos posicionados em pontos estratégicos (DASSOT; CONSTANT; FOURNIER, 2011; FAVORSKAYA; JAIN, 2017).

Os dados TLS podem ser aplicados em processamento de árvore individual, em que uma única árvore é escaneada e modelada computacionalmente, ou em nível de parcela baseando-se na detecção de árvores (LIANG et al., 2016). Esse segundo é o processamento mais comum. O processamento dos dados obtidos por TLS é de certa forma similar aos dados ALS, principalmente porque a primeira etapa também envolve a classificação dos pontos do solo para geração do MDT (DASSOT; CONSTANT; FOURNIER, 2011). Já para a detecção das árvores e mensuração de dap, normalmente se realiza o recorte da nuvem entre as alturas 1,25 e 1,35 m acima do solo, e nesse recorte são aplicados métodos de agrupamento ou segmentação de formas, nos quais busca-se o reconhecimento de padrões circulares ou em curvas (DASSOT; CONSTANT; FOURNIER, 2011; VAN LEEUWEN; NIEUWENHUIS, 2010). Nas formas detectadas então são estimados os valores de diâmetro (dap). Partindo-se do dap, no qual permite-se a localização da árvore, são determinados diâmetro em outras alturas e a altura total da árvore, permitindo, de forma limitada, a análise de afilamento da árvore (VAN LEEUWEN; NIEUWENHUIS, 2010).

O TLS tem demonstrado melhor exatidão na estimativa de diâmetros das árvores, porém apresenta dificuldades em certos aspectos, como na diferenciação de troncos e galhos (VAN LEEUWEN; NIEUWENHUIS, 2010). Devido às metodologias de dados TLS serem derivadas da detecção das árvores, o sucesso dessa etapa é diretamente relacionado ao sucesso das demais medidas ou estimativas (LIANG et al., 2016). É importante considerar que a capacidade de detecção das árvores é relacionada diretamente com a densidade da floresta, apesar de que o aumento do número de posições do escaneamento pode diminuir o efeito da densidade até certo limite (LIANG et al., 2016; VAN LEEUWEN; NIEUWENHUIS, 2010).

A estimativa da altura de árvores por TLS é menos precisa do que pelo ALS, pois as oclusões das folhas nas porções mais altas das árvores são comuns (VAN LEEUWEN; NIEUWENHUIS, 2010). Dessa forma, é comum que os dados TLS subestimem as alturas (LIANG et al., 2016). As estimativas de biomassa e volume derivadas de TLS de maneira geral são acuradas e demonstram-se muito promissoras devido ao fato de serem passíveis de mensuração diretamente na nuvem de pontos (LIANG et al., 2016; WHITE et al., 2016). Além dessas variáveis, dados de TLS podem ser aplicados para análise de clareiras, estimativa de LAI, classificação de espécies

florestais baseadas em padrões de casca, análise da qualidade de madeira, detecção de mudanças na floresta, entre outros (DASSOT; CONSTANT; FOURNIER, 2011; LIANG et al., 2016; VAN LEEUWEN; NIEUWENHUIS, 2010).

Apesar dos resultados promissores do TLS para várias aplicações, uma das principais limitação do TLS é o custo, visto que ele consegue cobrir áreas pequenas, acaba tornando-se caro, principalmente quando mais escaneamentos por local forem necessários, pois aumenta tanto o tempo de escaneamento e o processamento dos dados torna-se mais difícil (DASSOT; CONSTANT; FOURNIER, 2011). Outra limitação é a influência da densidade da floresta, sendo que o TLS é atualmente mais indicado para plantios (DASSOT; CONSTANT; FOURNIER, 2011) e em muitos casos a área que será escaneada precisa ser pré-preparada com a remoção de vegetação baixa para permitir a visada do sensor Laser (LIANG et al., 2016). Ainda, mesmo não sendo um sensor passivo, o TLS é afetado por algumas condições como o vento, pois esse altera a posição dos objetos, e chuva porque causa diminuição do número de pontos (DASSOT; CONSTANT; FOURNIER, 2011; FAVORSKAYA; JAIN, 2017). Devido à essas limitações, o uso de TLS em inventário florestal ainda não está completamente consolidado, porém uma possível aplicação desses dados é na calibração de outros sensores, como o ALS (LIANG et al., 2016; WHITE et al., 2016).

1.2.2.3 Fotogrametria moderna

A fotogrametria tem como definição a obtenção de acurada e precisa informação 3D a partir de imagens (GRANSHAW, 2016). A fotogrametria deriva dois principais ramos, o da fotogrametria métrica (as mensurações propriamente ditas) e a fotogrametria interpretativa, também chamada de fotointerpretação ou interpretação de imagens (WOLF; DEWITT; WILKINSON, 2014).

A fotogrametria métrica, além de apresentar a caracterização espectral dos alvos imageados, permite a obtenção de informações 3D a partir das imagens, desde que seja possível a aplicação dos princípios de paralaxe (DURRIEU et al., 2015), que se trata de um deslocamento em objetos causado pela diferença de visada em diferentes fotografias (GRANSHAW, 2016). Para que sejam possíveis mensurações nas fotografias é preciso que primeiramente seja resolvida a geometria de aquisição das imagens, que compreende as orientações interior e exterior (DURRIEU et al., 2015). A orientação interior trata da definição dos parâmetros de geometria do sistema

imageado (do sistema de lentes da câmera), e resolve parâmetros como ponto principal, distância focal calibrada e distorções das lentes (GRANSHAW, 2016; WOLF; DEWITT; WILKINSON, 2014). A orientação exterior trata do posicionamento da imagem no sistema, tratando de parâmetros de translação e rotação (ANDRADE, 2003), e pode ser ainda dividida em orientação relativa, em que se determina a relação entre as fotografias a partir de equações de colinearidade, e absoluta, em que esse sistema local é transferido para um sistema de coordenadas definido, a partir do uso de coordenadas de pontos de controle (DURRIEU et al., 2015; WOLF; DEWITT; WILKINSON, 2014). O processo de ajustamento de várias fotografias aéreas em um único processo, com o objetivo de extrair coordenadas x , y e z , é chamado de aerotriangulação (DURRIEU et al., 2015).

Para a utilização da aerotriangulação é necessário garantir certas condições na tomada das fotografias. Entre essas condições, está a necessidade de utilizar câmeras fotográficas com alta qualidade geométrica (MORGAN; GERGEL; COOPS, 2010), e calibradas de forma que os parâmetros internos da câmera sejam conhecidos a priori (ANDRADE, 2003; GRANSHAW, 2016). Além da câmera métrica, para realizar a conexão entre as diversas fotografias é necessário o uso de pontos de controle (GCP). No caso de um único estereopar devem existir no mínimo 4 pontos com coordenadas 3D e 3 pontos com pelo menos coordenadas x e y , porém no caso do ajustamento em blocos é necessário o uso de mais pontos (WOLF; DEWITT; WILKINSON, 2014). É importante também considerar o posicionamento dos pontos, sendo que se recomenda que os pontos horizontais sejam bem espalhados, e que os verticais sejam posicionados nos cantos do modelo (WOLF; DEWITT; WILKINSON, 2014).

Outro importante ponto que deve ser analisado é a escala necessária para o projeto em questão, sendo que essa é função da distância focal da câmera e altura de voo (MORGAN; GERGEL; COOPS, 2010). De maneira geral, planeja-se a altura do voo com base no equipamento disponível e na escala necessária. Normalmente recomenda-se escalas pequenas (1:30.000–1:100.000) para reconhecimento de tipos de vegetação em grupos generalizados, escalas médias (1:10.000–1:30.000) para reconhecimento de alguns tipos de florestas específicas ou mesmo algumas espécies em plantios homogêneos, e escalas grandes (1:2.500–1:10.000), para detecção de árvores individuais (WEST, 2015).

Além da altura, outro ponto importante no planejamento do voo é a definição dos valores de recobrimento longitudinal e lateral, sendo que o recobrimento longitudinal é o recobrimento entre imagens em uma mesma linha ou sequência de tomada, e o lateral é o recobrimento entre duas linhas (GRANSHAW, 2016). De acordo com Wolf, Dewitt e Wilkinson (2014), para possibilitar a aplicação de técnicas de estereoscopia (para obtenção de coordenadas 3D) é necessário um recobrimento longitudinal para garantir que não existam falhas devido à variações no terreno e da aeronave, e esse valor é normalmente de 60%. A utilização de 60% de sobreposição permite que cerca de 20% da área de cada imagem seja visível nas duas próximas imagens da mesma linha, ou seja, que a área seja visível em 3 imagens. No caso do recobrimento lateral, geralmente se utilizam valores menores, pois este é mais importante no sentido de evitar falhas entre as linhas de voo, e possibilitar o descarte de áreas de borda da fotografia (devido às maiores distorções), e geralmente é utilizado em 30%, podendo chegar até 60% em alguns casos em que se deseja uma precisão muito alta (WOLF; DEWITT; WILKINSON, 2014).

Também é importante a observação das condições meteorológicas no momento do recobrimento fotográfico, sendo que a presença de nuvens afeta as imagens, que em geral devem ser evitadas, mas que podem ser benéficas em situações em que dias nublados são favoráveis, como para sobrevoar áreas de floresta ou ambientes urbanos, devido ao fato de que os objetos altos geram muitas sombras quando há presença de sol (WOLF; DEWITT; WILKINSON, 2014). Condições de neblina, chuva, fumaça, poeira e ventos fortes, por outro lado, geralmente impossibilitam a tomada de fotografias (WOLF; DEWITT; WILKINSON, 2014).

As fotografias aéreas podem ser aplicadas para estimativas da estrutura de povoamentos, prover fonte de informações para mapeamentos de vegetação, ou ainda promover informações acerca de ataques de insetos ou doenças na floresta (WEST, 2015). O tipo de informação que pode ser obtido das imagens porém é relacionado a diversos fatores, como a escala e a porção do espectro abrangido na câmera utilizada (WEST, 2015). De maneira geral, segundo Morgan, Gergel e Coops (2010), as fotografias aéreas são tomadas principalmente em bandas pancromáticas, na região do espectro visível (RGB) e na região do infravermelho.

Nos últimos anos o desenvolvimento de técnicas de processamento computacional permitiu que sejam extraídas nuvens de ponto das imagens, similares

às nuvens LiDAR, porém restritas à superfície da copa das árvores, principalmente em áreas de vegetação densa, já que as faixas espectrais utilizadas não permitem penetração na vegetação (DURRIEU et al., 2015; WHITE et al., 2016). Apesar disso, as nuvens de pontos provenientes das imagens podem ser utilizadas para geração de MDS, que pode ser normalizado em um CHM, desde que haja um MDT de outra fonte disponível, e com este CHM é possível detecção de árvores e estimativas de alturas, similar ao ALS (WHITE et al., 2016). A exatidão da obtenção de alturas por fotogrametria depende de vários fatores, relacionados à qualidade das imagens e aspectos da área e elementos alvo (geometria da copa, topografia, exatidão do MDT utilizado, entre outros), porém em geral se observa subestimativa dos valores de alturas devido à suavização do topo das árvores (DURRIEU et al., 2015). Da mesma forma, a detecção das árvores é limitada por alguns fatores, entre eles a presença de árvores suprimidas, que não podem ser detectadas porque não são visíveis na superfície (DURRIEU et al., 2015). Apesar dessa limitação, as nuvens provenientes das imagens contêm também informações espectrais, que podem ser úteis na análise de composição de espécies (WHITE et al., 2016).

A fotogrametria apresenta certos erros, classificados como geométricos ou radiométricos, e podem ser sistemáticos ou casuais (MORGAN; GERGEL; COOPS, 2010). Os erros geométricos se referem a erros de posicionamento e podem ser relacionados a problemas no equipamento, estabilidade da aeronave e erros de deslocamento de objetos devido à topografia do terreno (MORGAN; GERGEL; COOPS, 2010). Os erros radiométricos são normalmente relacionados à calibração da câmera, e também advindos de condições de iluminação no momento da tomada das imagens, e podem ser corrigidos ou suavizados por técnicas de processamento de imagens (MORGAN; GERGEL; COOPS, 2010). A eliminação de deslocamentos devido à topografia do terreno é corrigida no processo chamado de ortorretificação, em que a ortofoto é corrigida em função de um modelo do terreno (WOLF; DEWITT; WILKINSON, 2014), ou em alguns casos por pontos de controle no terreno (MORGAN; GERGEL; COOPS, 2010).

1.2.3 Veículos Aéreos Não Tripulados (VANT)

1.2.3.1 Definições e contexto

Os Veículos aéreos Não Tripulados (VANTs, do original UAV - *Unmanned Aerial Vehicles*), também são em alguns casos denominados de aeronaves não tripuladas, ou aeronaves remotamente pilotadas (RPA) (DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO (DECEA), 2016a). Apesar de serem termos similares, o termo VANT sugere veículos que não apresentam pessoas embarcadas, e que portanto, podem ser pilotados remotamente ou autonomamente, enquanto que RPA restringe-se para aeronaves remotamente pilotadas, excluindo as autônomas (FAHLSTROM; GLEASON, 2012). Em ambos os casos, quando se pretende incluir a estação em torno do veículo, inclui-se a palavra sistema, tornando-se então UAS (*Unmanned Aerial System*, ou Sistema Aéreo Não Tripulado), e RPAS (*Remotely Piloted Air System*). O termo *drone* é normalmente utilizado de forma coloquial, principalmente para veículos aéreos multirotores, devido ao ruído que os motores causam. Nesse trabalho foi adotado o termo VANT, por ser o mais comum, porém deve-se observar que a legislação brasileira adota o termo RPA. Deve-se deixar claro, porém, que nesse trabalho o termo VANT não se refere à veículos autônomos, que são proibidos no Brasil.

Relatos de veículos aéreos sem pessoas embarcadas datam de idades de aproximadamente 400 D.C. tanto na Europa como na China, porém o desenvolvimento de VANTs como se conhece hoje se iniciou na época da Primeira Guerra Mundial e ganhou maior força na Segunda Guerra Mundial, após o desenvolvimento de controle de aeronaves via rádio transferência (DALAMAGKIDIS, 2015a). O desenvolvimento desses primeiros VANTs teve principalmente fins militares (FAHLSTROM; GLEASON, 2012), sendo posteriormente adaptado para fins civis e diversas aplicações, principalmente para os menores veículos aéreos (DALAMAGKIDIS, 2015a). O uso de VANTs em aplicações civis se desenvolveu principalmente após a Guerra Fria, pois observou-se que com os melhoramentos em reconhecimento e controle dos veículos aéreos não tripulados, esses eram capazes de similares capacidades mas com menores riscos em relação aos pilotadas (WATTS; AMBROSIA; HINKLEY, 2012). Já durante os anos 80 e principalmente 90, os esforços para a adaptação de sensores para uso em VANTs com fins científicos se

intensificaram, já que um dos principais problemas encontrados no começo foi o fato de que os veículos aéreos e sensores desenvolvidos para fins militares eram grandes, e esse tamanho inviabilizava as pesquisas científicas devido ao preço (WATTS; AMBROSIA; HINKLEY, 2012).

No Brasil, desde julho de 2017 até fevereiro de 2018 foram registrados mais de 33 mil VANTs no sistema da Agência Nacional de Aviação Civil (ANAC), sendo que a maior parte desses é cadastrado por pessoas físicas (94,22%) e para fins recreativos (63,84%) (ANAC, 2018). Os estados com maior número de registros nesse mesmo período são, respectivamente, São Paulo (36,32%), Rio de Janeiro (12,74%), Minas Gerais (9,29%) e Paraná (6,46%) (ANAC, 2018).

1.2.3.2 Componentes básicos

Um VANT normalmente é composto por pelo menos um veículo e sua carga, uma ou mais estações de controle no solo e um sistema de comunicação (FAHLSTROM; GLEASON, 2012). Além disso, de acordo com o tipo de veículo, podem ser necessários outros elementos, como, por exemplo, um sistema de decolagem e pouso para alguns VANTs (CHAO; CHEN, 2012).

Cada veículo precisa ter condições de levantar voo, se manter no ar e ser guiado para que possa ser um veículo aéreo e, além disso, informações sobre o estado do veículo aéreo são imprescindíveis para o seu controle (ELKAIM; LIE; GEBRE-EGZIABHER, 2015). Segundo Fahlstrom e Gleason (2012), a maioria dos VANTs atuais é controlado por um sistema eletrônico chamado de auto piloto, que é composto por sistemas sensores que monitoram as condições do voo e controladores e atuadores que guiam a navegação do veículo conforme padrões pré-definidos, além de outros componentes. Os principais elementos do estado de um veículo aéreo que precisam ser conhecidos são: posição, velocidade, atitude, velocidade do ar, ângulo (lateral e frontal), e rotações (ELKAIM; LIE; GEBRE-EGZIABHER, 2015).

O principal sistema sensor existente atualmente nos veículos aéreos é o IMU (*inertial measurement unit*, ou unidade de mensuração inercial), que compreende giroscópios, acelerômetros sensores magnéticos, e/ou sensores de pressão (BEARD; MCLAIN, 2012; CHAO; CHEN, 2012). Os sensores de pressão são altímetros e sensores de velocidade do ar (BEARD; MCLAIN, 2012). Altímetros são importantes para manter a altitude constante, e normalmente medem a diferença de pressão

estática conforme alterações na altitude do veículo aéreo (FAHLSTROM; GLEASON, 2012), já os sensores de velocidade do ar medem a diferença entre a pressão estática e dinâmica, a partir da qual determina-se a velocidade do ar (FAHLSTROM; GLEASON, 2012). Os acelerômetros medem a aceleração do veículo aéreo e são normalmente baseados no movimento de certa massa conhecida (BEARD; MCLAIN, 2012; CHAO; CHEN, 2012). Os magnetômetros ou bússolas digitais podem ser usados para navegação, pois são capazes de medir a força do campo magnético e seu ângulo na maior parte do globo terrestre, porém esses sistemas sofrem muitas interferências eletromagnéticas, portanto requerem cuidados especiais (BEARD; MCLAIN, 2012).

Os giroscópios (também chamados de sensores de atitude) medem as alterações de posição nos ângulos de rolagem, arfagem e guinada (respectivamente *pitch*, *yaw* e *roll*), desde que o veículo aéreo contenha um giroscópio para cada ângulo (CHAO; CHEN, 2012; FAHLSTROM; GLEASON, 2012). A rolagem, a arfagem e a guinada se referem a movimentos nos eixos X, Y e Z, respectivamente. Os sistemas GPS que atualmente estão embarcados nos VANTs podem fornecer basicamente todas essas informações de altitude, atitude e velocidade do ar, e apesar dessas informações não serem atualizadas de forma rápida suficiente para manter a estabilização do veículo aéreo, são informações úteis e suficientes para fins de navegação, por exemplo (FAHLSTROM; GLEASON, 2012).

1.2.3.3 Classificação e modelos existentes

Existem várias classificações para VANTs, baseadas em peso de decolagem (máximo, ou médio), tamanho, condições de operações, desempenho, tipo e área de operação, entre outras (DALAMAGKIDIS, 2015b; INTERNATIONAL CIVIL AVIATION ORGANIZATION - ICAO, 2015). A classificação por peso é uma das mais conhecidas, e é importante porque interfere no risco do impacto no solo no caso de um acidente (DALAMAGKIDIS, 2015b).

Mesmo dentro das classificações de peso, existem diversas categorizações, porém a legislação brasileira atual sobre o tema apresenta três classes, sendo 1 acima de 150 kg, 2 entre 25 kg e 150 kg, e classe 3 até 25 kg (ANAC, 2017a). A regulamentação americana sobre VANTs apresenta uma classificação semelhante, em que os VANTs até 55 libras (aproximadamente 25 kg) são classificados como

pequenos, e são regulados por uma norma específica, chamada “*Part 107 - Small Unmanned Aircraft Systems*” (FEDERAL AVIATION ADMINISTRATION (FAA), 2016).

Outra classificação muito comum é por tipo, geralmente relacionado ao tipo de asas e número de motores. Dentro dos tipos de asas principais, tem-se os drones de asa fixa, e de asas giratórias, além de balões ou dirigíveis, e asas batedoras, e os modelos híbridos (ANDERSON; GASTON, 2013). Dentro da categoria de VANT de asas giratórias existem várias possibilidades, como os com uma só hélice (helicóptero), ou com várias (quadricóptero, hexacóptero, heptacóptero e outros). Cada tipo de VANT tem suas principais características, vantagens e desvantagens, algumas das quais destacadas na TABELA 2.

TABELA 2 - ASPECTOS DA APLICAÇÃO DE DIFERENTES TIPOS DE VANT EXISTENTES

Aspecto	Tipo de VANT			
	Multirotor	Asa fixa	Helicóptero	Dirigível
Carga máxima	Baixa	Alta	Média	Alta
Decolagem e pouso	Vertical	Pode precisar de pista ou catapulta	Vertical	Vertical
Velocidade	Definida pelo piloto	Rápida		Devagar
Trajatória	Capaz de seguir rotas e pairar no ar	Capaz de seguir rotas longas	Capaz de seguir rotas e pairar no ar	Depende do vento
Área coberta	Baixa	Alta	-	-
Duração da bateria	Baixa	Alta	-	-
Condições de vento	Estável para ventos fortes	Estável para ventos fracos	Estável para ventos fortes	Suscetível ao vento
Transporte	Fácil de transportar	Desmontado facilmente	Fácil de transportar	Difícil de transportar

FONTE: Adaptado de Anderson e Gaston (2013), Jorge e Inamasu (2014) e Vasterling e Meyer (2013).

1.2.3.4 Câmeras e outros sensores remotos

Uma das grandes vantagens dos VANTs para o sensoriamento remoto é a possibilidade da embarcação de diversos tipos sensores nesses veículos. Em alguns modelos, é possível alternar câmeras (ou até outros sensores) de forma prática, pois são VANTs sem sensores fixos, enquanto que outros modelos já apresentam sensores integrados. Os sensores utilizados em VANTs no geral são os mesmos já utilizados em aeronaves tripuladas e em satélites, porém adaptados em tamanho para poderem ser transportados pelo VANTs, sendo que ainda hoje um dos maiores obstáculos da integração de sensores em VANTs é a sua capacidade de carga (MEJIAS; LAI; BRUGGEMANN, 2015; PAJARES, 2015). Ainda, existe a possibilidade

de que as imagens desse sensores tenham menor qualidade radiométrica, devido à redução de tamanho dos sensores e problemas na estabilidade do VANT (vibrações, variação com vento), que podem alterar qualidade dos dados coletados (ANDERSON; GASTON, 2013). Essas condições são mais limitantes conforme o tamanho da VANT, sendo que os menores são os mais afetados.

Os principais tipos de sensores atualmente adaptados para VANTs são passivos como câmeras em diversas faixas espectrais, e ativos, como o LiDAR e radar. Os primeiros sensores utilizados foram basicamente câmeras digitais comuns, normalmente RGB, adaptadas para serem embarcadas nos VANTs. Em estudo apresentado em 2014, observou-se que a grande maioria (aproximadamente 80%) dos trabalhos encontrados até então utilizavam câmeras RGB, uma menor porcentagem câmeras infravermelhas e termais (menos de 30% dos trabalhos), e uma menor parcela ainda bandas multiespectrais (SHAHBAZI; THÉAU; MÉNARD, 2014). Câmeras no espectro visível em geral são principalmente utilizadas no monitoramento da vegetação (PANEQUE-GÁLVEZ et al., 2014), mas também podem ser utilizadas para obter parâmetros da estrutura da floresta, como obtenção de índices de cobertura de copa e obtenção de modelos de altura de copa em certas florestas (BONNET; LISEIN; LEJEUNE, 2017; CHIANUCCI et al., 2016; MLAMBO et al., 2017).

Os sensores infravermelhos, principalmente os que atuam na região do infravermelho próximo (NIR), são muito utilizados na área florestal devido à capacidade desses de capturarem informações da vegetação (CHIANUCCI et al., 2016). Muitas das câmeras infravermelhas, principalmente as primeiras comercializadas, eram câmeras RGB modificadas (LEBOURGEOIS et al., 2008; STANTON et al., 2017). Aplicações incluem obtenção de parâmetros da estrutura de árvores (altura, diâmetro de copa), obtenção de índices de vegetação, classificação de algumas espécies de árvores, detecção de doenças e pragas na floresta (LEHMANN et al., 2015; LISEIN et al., 2015; ZARCO-TEJADA et al., 2014). Essas técnicas normalmente são somente possíveis em tipos florestais temperados, portanto, não aplicáveis à realidade das florestas brasileiras.

Os sensores que atuam na região termal (parte do espectro infravermelho conhecida como de ondas curtas – SWIR), atuam de forma a mensurar a energia emitida por objetos. Existem várias aplicações desse tipo de comprimento de onda em vários setores (ambiental, médico, de infraestrutura), podendo-se citar o monitoramento e detecção de incêndios, perdas de energia, monitoramento de vida

selvagem, identificação de doenças em plantações, estresse hídrico e outras (GARCIA-RUIZ et al., 2013; ZARCO-TEJADA; GONZÁLEZ-DUGO; BERNI, 2012).

As câmeras multiespectrais ou hiperespectrais geralmente coletam informações nas mesmas faixas imageadas por outros sensores, porém de forma segmentada, permitindo explorar melhor as diferenças em cada pequena variação do espectro eletromagnético (SAARINEN et al., 2018). A diferença entre multiespectral e hiperespectral está no fato de que as primeiras normalmente apresentam entre 5-12 bandas, enquanto que as segundas apresentam centenas de bandas (ADÃO et al., 2017). No contexto deste trabalho, os dois tipos serão apresentados de forma conjunta, pois as aplicações são similares. Essas câmeras podem ser utilizadas em várias aplicações e alguns exemplos são detecção de estresse na vegetação (doenças, pragas) e identificação de espécies (GARCIA-RUIZ et al., 2013; NÄSI et al., 2015; SAARINEN et al., 2018).

A introdução de sistemas LiDAR em VANTs se desenvolveu nos últimos anos, porém esses ainda são relativamente limitados por apresentarem um custo maior comparado aos sensores passivos. Além disso, o uso de LiDAR em VANTs apresenta alguns desafios, como a calibração do sistema, fusão dos dados LiDAR e imagens, e processamento dos dados (FAVORSKAYA; JAIN, 2017). As aplicações do VANT-LiDAR são similares aos ALS, incluindo-se a detecção de árvores, mensuração de atributos florestais (altura, área de copa, volume), densidade de plantas, cobertura do dossel, biomassa aérea, entre outros (SANKEY et al., 2017; WALLACE et al., 2016).

Por fim, os sistemas Radar ou SAR também estão sendo adaptados para utilização em VANTs, e contam com a vantagem de operar em qualquer condição meteorológica (GENS, 2009), além de apresentarem outras informações sobre a interação das ondas com os objetos (RICHARDS, 2009). Atualmente existem poucos sensores e trabalhos desenvolvidos, sendo esses focados em predição de biomassa aérea (ROBINSON et al., 2013). Segundo Mejias, Lai e Bruggemann (2015), um dos principais empecilhos atuais da aplicação dos sensores radar em VANTs é o alto custo de energia.

1.2.3.5 Legislação do uso de VANTs no Brasil

No Brasil a operação de veículos não tripulados para uso civil (portanto, excluindo-se os militares) foi regulamentada em maio de 2017 a partir do Regulamento

Brasileiro de Aviação Civil Especial nº 94/2017 (RBAC-E nº 94/2017) ANAC (ANAC, 2017a). Além disso, no Brasil devem ser consideradas as normas do DECEA (Departamento de Controle do Espaço Aéreo), da ANATEL (Agência Nacional de Telecomunicações), e do Ministério da Defesa.

Segundo a norma da ANAC, os veículos popularmente conhecidos como *drones*, devem ser enquadrados nas categorias de Aeromodelo ou Aeronave Remotamente Pilotada (RPA). A diferença entre aeromodelo está no fato de que esses são somente os veículos aéreos não tripulados com fim de recreação, enquanto que os veículos aéreos com qualquer outro fim (comercial ou experimental por exemplo) são considerados RPAs (ANAC, 2017a). Nesse caso, para manter a concordância com o resto do trabalho, o termo RPA foi substituído por VANT, mantendo-se o termo aeromodelo para os veículos com fim recreativo. Dentre os VANTs existem três classes: classe 1 – veículos aéreos com peso de decolagem acima de 150 kg; classe 2 - com peso de decolagem maior que 25 kg e menor ou igual a 150 kg; e classe 3 - com peso de decolagem até 25 kg ANAC (ANAC, 2017a).

Para a operação de VANTs e aeromodelos acima de 250 g, a ANAC determina que se deve observar uma distância mínima de 30 m de qualquer pessoa não envolvida com a operação, exceto em casos em que haja barreira mecânica (ANAC, 2017a) e em alguns casos específicos apresentados na normativa. Todo piloto e observador de VANT deve ser maior de 18 anos, e para o piloto necessita-se ainda ter Certificado Médico Aeronáutico (CMA) para as classes de VANT 1 e 2, e licença e habilitação emitida e validada pela ANAC para voos acima de 400 pés (120 m) (ANAC, 2017a).

Os voos podem ser executados com: linha de visada visual (*Visual Line of Sight – VLOS*), no qual o piloto remoto não necessita de aparelhos para visualizar veículo aéreo durante todo o voo; linha de visada estendida (*Extended Visual Line of Sight – EVLOS*), na qual o piloto somente consegue visualizar o veículo aéreo com uso de equipamentos como lentes e, portanto, necessita de operadores auxiliares para acompanhar o veículo aéreo e manter distância a seguir; ou ainda além da linha de visada (*Beyond Visual Line of Sight – BVLOS*), quando não se atendem as operações VLOS ou EVLOS. Na execução do voo não é permitido o transporte de cargas, pessoas ou animais (exceto em alguns casos definidos), e não é permitida a execução de voos autônomos (em que o piloto remoto não tem controle durante todo ou parte do voo), sendo necessária a presença de um piloto durante toda a operação,

que somente pode operar um veículo aéreo por vez, e este deve manter relatórios de voos de veículos aéreos nas classes 1 e 2 (ANAC, 2017a).

Para a decolagem o veículo aéreo, necessita-se de alguns documentos, de acordo com o tipo, classe de VANT e tipo de voo realizado, conforme TABELA 3.

TABELA 3 - REQUERIMENTOS DA RBAC-E 94/2017 DA ANAC PARA A OPERAÇÃO DE VEÍCULOS AÉREOS NÃO TRIPULADOS NO BRASIL

Veículo aéreo e tipo de voo	Documentação necessária
VANT até 250 g	<ul style="list-style-type: none"> • Não há necessidade de documentação pela ANAC.
Aeromodelo acima 250 g	<ul style="list-style-type: none"> • Cadastro na ANAC e identificação no veículo aéreo.
>250 g VANT ≤25 kg Voo até 400 pés com VLOS ou EVLOS	<ul style="list-style-type: none"> • Cadastro na ANAC e identificação no veículo aéreo; • Seguro com cobertura a terceiros (exceto veículo aéreo do Estado); • Documento de avaliação de risco; • Manual de voo.
>250 g VANT ≤25 kg Voo até 400 pés BVLOS	<ul style="list-style-type: none"> • Seguro com cobertura a terceiros (exceto veículo aéreo do Estado); • Certificado experimental ou matrícula; • Certificado de aeronavegabilidade; • Documento de avaliação de risco; • Manual do voo.
>250 g VANT ≤25 kg Outras situações	<ul style="list-style-type: none"> • Seguro com cobertura a terceiros (exceto veículo aéreo do Estado); • Licença e habilitação emitida pela ANAC; • Certificado experimental ou matrícula; • Certificado de aeronavegabilidade; • Documento de avaliação de risco; • Manual do voo.
> 25 kg VANT ≤ 150 kg	<ul style="list-style-type: none"> • Seguro com cobertura a terceiros (exceto veículo aéreo do Estado); • Licença e habilitação emitida pela ANAC; • CMA emitido pelo comando da aeronáutica; • Certificado experimental ou matrícula; • Certificado de aeronavegabilidade; • Documento de avaliação de risco; • Manual de voo.
VANT > 150 kg	<ul style="list-style-type: none"> • Seguro com cobertura a terceiros (exceto veículo aéreo do Estado); • Licença e habilitação emitida pela ANAC; • CMA emitido pelo comando da aeronáutica; • Certificado de tipo; • Certificado de aeronavegabilidade; • Documento de avaliação de risco; • Manual de voo.

FONTE: Adaptado de ANAC (2017a).

Nota: o peso do VANT se refere ao peso no momento da decolagem

Para os veículos aéreos com peso de decolagem inferior à 250 g não se necessita de qualquer tipo de cadastro, já para os veículos aéreos com mais de 250 g até 25 kg, desde que voem até 400 pés (120m) de altitude e apresentem linha de visada (com ou sem ajuda de operadores) necessita-se somente de um cadastro na

ANAC (ANAC, 2017a). Para a realização do cadastro na ANAC deve-se utilizar o Sistema de Aeronaves não Tripuladas (SISANT), no qual cada veículo aéreo deve ser cadastrado de forma única, fornecendo-se para tanto o cadastro de pessoa física ou jurídica para vínculo, dados do veículo aéreo (modelo, marca, ano entre outros), número de identificação, e fotografia que possibilite identificar o veículo aéreo (ANAC, 2017b).

Os demais veículos aéreos devem ser registrados de acordo com especificações do Registro Aeronáutico Brasileiro (Resolução nº 293, de 9 de novembro de 2013), e obter um Certificado de Matrícula ou Certificado de Marca Experimental ANAC (ANAC, 2017a). Para o registro deve-se fazer um pedido juntamente à ANAC, entregando a documentação necessária para cada categoria (pública, privada, marca nacional, importada, entre outros) e observando-se prazos de validade do registro (ANAC, 2013).

Além de registro, para veículos aéreos que irão atuar em altitudes acima de 400 pés (120 m), e ou fora da linha de visada, necessita-se que exista um projeto autorizado pela ANAC (ANAC, 2017a). Para a autorização de um projeto seguem-se normas de acordo com a classe de VANT e o voo que será realizado, mas de forma geral em todos os casos necessita-se que se demonstre que o equipamento é adequado para o voo desejado, e que se apresente o manual do voo, manual de manutenção e relatório de segurança (ANAC, 2017a). Demais requerimentos, relativos à segurança do voo, equipamentos de emergência, navegação e iluminação são específicos para as classes 2 e 3, enquanto que para a classe 1 de VANT necessita-se de Certificado de Tipo (ANAC, 2017a). Os Certificados de Tipo são necessários às demais aeronaves (tripuladas) que desejam operar no espaço aéreo brasileiro, e para obtenção de um desses certificados necessita-se seguir a norma RBAC nº 21, e exige-se a apresentação de documentação como vistas do veículo aéreo e dados básicos, e essas passam por ensaios e inspeções realizadas pela ANAC (ANAC, 2015).

Ainda, conforme a (ANAC, 2017a), os veículos aéreos com peso acima de 25 kg e/ou que irão operar em altitude acima de 400 pés (120 m) ou fora da linha de visada, devem ainda apresentar um certificado de aeronavegabilidade, que pode ser dos tipos: Certificado de Autorização de Voo Experimental (CAVE), Autorização Especial de Voo (AEV), Certificado de Aeronavegabilidade Especial para RPA

(CAER); Certificado de Aeronavegabilidade categoria restrita; ou Certificado de Aeronavegabilidade padrão.

Além das normas da ANAC, devem ser consideradas outras normas, como a do DECEA para regulamentação do espaço aéreo. A principal normativa do DECEA é a ICA 100-40 publicada em dezembro de 2016, substituindo a versão anterior (de 2015) de forma a normalizar os procedimentos aéreos com base nas regras da OACI (*International Civil Aviation Organization*) (DECEA, 2016a). Além da ICA 100-40, pilotos e operadores de VANT devem observar também a ICA 100-12, na qual são publicadas as Regras do Ar (DECEA, 2016b) e ICA 100-37, na qual são publicadas as informações sobre o Serviço de Tráfego Aéreo (ATS) (DECEA, 2017a).

O DECEA parte do princípio que um VANT deve adequar-se às mesmas normas das demais aeronaves que utilizam o espaço aéreo brasileiro, porém considerando as especificidades apresentadas ICA 100-40 (DECEA, 2016a). Vale ressaltar ainda que a ICA 100-40 não trata de aeromodelos, mas somente de VANTs. A regulamentação ICA 100-40 do DECEA trata da regulamentação do acesso ao espaço aéreo e, para tanto, devem-se atentar às normas apresentadas na TABELA 4, e demais casos determinados na ICA 100-40 (DECEA, 2016a).

O processo de solicitação de acesso ao espaço aéreo deve ser iniciado após certificação/habilitação e emissão de documentos das demais autoridades regulamentadoras, no caso ANAC e ANATEL para VANTs com peso inferior a 25 kg operando até 120 m, e do Ministério da Defesa (MD) para aerolevantamentos (DECEA, 2016a). O processo é realizado pelo sistema SARPAS (Sistema de Autorização para Acesso ao Espaço Aéreo por RPAS), e deve ser feito dentro do prazo mínimo determinado para cada caso (DECEA, 2016a). Nos casos em que há necessidade de NOTAM (*Notice to Airmen*), a solicitação deve ser feita com no mínimo 18 dias de antecedência, e a autorização poderá ser emitida com prazo máximo de 3 meses (DECEA, 2016a).

Tanto nas ICA 100-40 e 100-12 são apresentadas recomendações para o planejamento de voo, para o qual deve-se: considerar condições meteorológicas, cálculo de combustível para o voo, planejamento alternativo para o caso em que não seja possível completar o voo, e condições pertinentes ao voo previstas na IAIP (Documentação Integrada de Informações Aeronáuticas) e ROTAER – informações referentes à restrições de aeródromos (DECEA, 2016a, 2016b). O plano de voo em

si, exigido para veículos aéreos acima de 25 kg, é definido na MCA 100-11 (DECEA, 2017b).

TABELA 4 - REGULAMENTAÇÃO DECEA PARA ACESSO AO ESPAÇO AÉREO BRASILEIRO

Normas gerais		<ul style="list-style-type: none"> • Necessária autorização emitida pelo DECEA; • Voos acima de 400 pés (120m) necessitam uso de transponder; • Permite-se o uso de mais que uma estação remota, não simultaneamente; • Operações em autódromos em que circulam aeronaves tripuladas só é permitida com autorização do administrador responsável por este, e durante a decolagem e pouso de um VANT todas atividades com aeronaves tripuladas devem ser suspensas; • Seguir as regras de voo visual ou por instrumentos (VFP ou IFR), conforme 100-12 "Regras do Ar"; • Utilizar linguagem e equipamentos adequados para contato entre RPS e serviço de tráfego aéreo (ATS); • VANT em uso noturno deve ter iluminação especificada em norma; • Operações BVLOS necessitam emissão de NOTAM*;
	Voos até 400 pés (120m) e < 25 kg	<ul style="list-style-type: none"> • Operar somente em condições meteorológicas que permitam visada a olho nu (VMC); • Operar em VLOS com afastamento máximo de 500m do piloto remoto; • Estar afastado verticalmente de no mínimo 30m de estruturas, edifícios e/ou animais (exceto com autorização do proprietário), e não sobrevoar áreas povoadas ou aglomerações de pessoas sem autorização; • Manter contato visual durante todo o voo;
	Até 30m	<ul style="list-style-type: none"> • Manter velocidade máxima de 30 Kts (60 km/h); • Afastamento mínimo de 3NM (5km) de aeródromos cadastrados e rotas conhecidas de aeronaves (exceto com autorização); • Solicitar autorização para acesso do espaço aéreo pelo SARPAS com no mínimo 45 min de antecedência do início pretendido;
	30-120m	<ul style="list-style-type: none"> • Manter velocidade máxima de 60 kts (120 km/h); • Afastamento mínimo de 5 NM (9 km) de aeródromos cadastrados e rotas conhecidas de aeronaves (exceto com emissão de NOTAM); • Solicitação para acesso ao espaço aéreo deve ser feita pelo sistema SARPAS com um mínimo de 2 dias úteis de antecedência;
	> 25 kg	<ul style="list-style-type: none"> • Independente da altura e tipo de operação, devem utilizar espaço aéreo segregado e de ter emissão de NOTAM; • Apresentar plano de voo;
	Outros	<ul style="list-style-type: none"> • Operações em áreas confinadas não configuram espaço aéreo (portanto não são reguladas pelo DECEA); • Voos em áreas de segurança, ou perigosas só podem ser sobrevoadas com autorização (de autoridades pertinentes a cada caso); • Próximo a estruturas críticas (estruturas como redes de abastecimento de água, gás, energia) manter distância de no mínimo 5km (exceto com autorização da concessionária).

FONTE: Adaptado da ICA 100-40 (DECEA, 2016a).

*NOTAM deve ser solicitada com no mínimo 18 dias de antecedência.

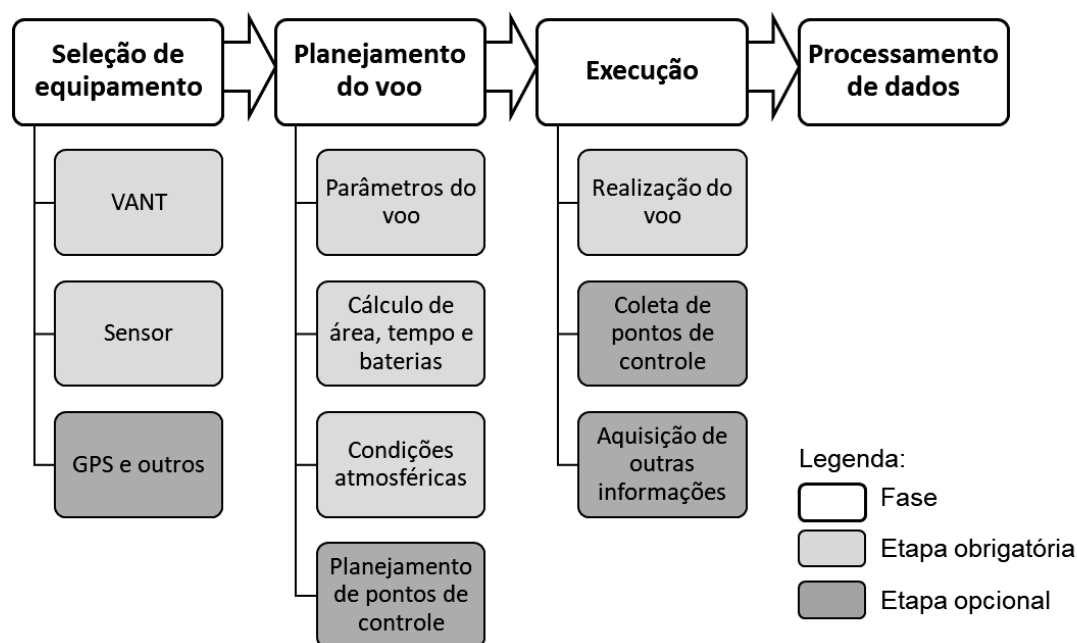
Por fim, além das normativas da ANAC e DECEA, a ANATEL determinou que todos os veículos aéreos não tripulados (tanto aeromodelos como VANTs) devem ser cadastrados e homologados, visto que esses utilizam radiofrequências (ANATEL, 2016). Para o cadastro, deve-se acessar o Portal da ANATEL online, e seguir as diretrizes publicadas no "Manual de Orientações: Homologação de DRONES"

(ANATEL, 2018). O cadastro na ANATEL é feito em etapas, sendo a primeira o cadastramento da pessoa física ou jurídica para acesso ao sistema, e após é necessário informar especificações técnicas do VANT (disponíveis no Certificado FCC), e os números de série do veículo aéreo e do controle (ANATEL, 2018). Após a finalização do pedido, deve-se aguardar a resposta da ANATEL sobre a solicitação, normalmente enviada em até 45 dias (ANATEL, 2018). Caso aprovado, será gerado um certificado de homologação e, a partir desse, o usuário deve confeccionar um selo com o número do certificado de homologação, que deve ser afixado no chassi do aparelho (ANATEL, 2018).

1.2.3.6 Aquisição de dados por meio de VANT

A aquisição de dados com VANTs requer várias etapas, que em alguns casos são gerais, e em outros específicas de acordo com a aplicação almejada e equipamentos utilizados. Além da aquisição física dos dados (fotografias, nuvem de pontos, coordenadas), os dados coletados normalmente passam por uma etapa de processamento, também variável com a aplicação e principalmente com o tipo de sensor utilizado. De maneira geral, a coleta de dados pode ser dividida em quatro etapas principais, conforme FIGURA 1.

FIGURA 1 - ETAPAS DO PROCESSO DE COLETA DE DADOS COM VANT



FONTE: A autora (2018).

1.2.3.6.1 Seleção de equipamento

A seleção do VANT adequado para o levantamento de dados deve ser feita levando-se em consideração os parâmetros apresentados na TABELA 2, e envolve informações sobre as outras etapas do levantamento, como a área de interesse e os sensores que serão utilizados. De maneira geral, os VANTs com asas fixas tem capacidade de cobrir áreas maiores e carregar sensores maiores (ANDERSON; GASTON, 2013; TOTH; JÓŹKÓW, 2016). Apesar disso, os VANTs de asas giratórias geralmente são mais flexíveis quanto à área de decolagem e pouso e geralmente tem custo menor (DRONE DEPLOY, 2017; JORGE; INAMASU, 2014).

A seleção do sensor em alguns casos está restrita ao VANT selecionado, porém deve-se principalmente à aplicação pretendida, pois câmeras em diferentes faixas do espectro e sensores ativos apresentam distintos resultados quanto à caracterização de alvos de interesse (TOTH; JÓŹKÓW, 2016). De maneira geral, a escolha do tipo de VANT e sensor são principalmente determinados pela resolução pretendida, extensão da área e objetivos do voo (GIORDAN et al., 2018).

Dependendo do sistema utilizado, tanto do VANT como do sensor, podem ser necessários equipamentos extras, como, por exemplo, uma estação base com receptor GNSS para utilização de sistema RTK em alguns VANTs (GERKE; PRZYBILLA, 2016; TOTH; JÓŹKÓW, 2016), em que se aplica georreferenciamento direto. Apesar disso, o mais comum método de georreferenciamento, principalmente para os sistemas que utilizam câmeras fotográficas, é a partir da utilização de pontos de controle (COLOMINA; MOLINA, 2014), chamados de GCP (pontos de controle no terreno), conhecido como georreferenciamento indireto (COLOMINA; MOLINA, 2014; TOTH; JÓŹKÓW, 2016). A necessidade da utilização de pontos de controle se dá porque esses permitem a transformação do sistema de coordenadas da imagem para o sistema de coordenadas métricas selecionado (NEX; REMONDINO, 2014), considerando-se que os sistemas GPS e IMU presentes nos VANTs não apresentam valores com precisão suficiente (NEX; REMONDINO, 2014).

A utilização de pontos de controle se dá pela disposição de alvos artificiais na área que será sobrevoada e da coleta das coordenadas (x, y e z) com equipamento que atenda a precisão adequada para a escala utilizada (LINDER, 2016; WOLF; DEWITT; WILKINSON, 2014). Em alguns casos é possível a utilização de alvos naturais, que são objetos ou feições existentes na área e que são identificáveis nas

imagens com precisão suficiente, porém esses são raros em áreas florestais (BREDE et al., 2017). Os pontos de controle artificiais devem ter cores que permitam bom contraste, um ponto que pode ser determinado com precisão no centro do alvo, e um tamanho satisfatório para a escala das imagens (WOLF; DEWITT; WILKINSON, 2014).

Outros possíveis equipamentos, que podem ser necessários em alguns projetos, são os de calibração radiométrica. Essa calibração radiométrica é aplicada nas imagens, e é necessária para se realizar análise entre dados de diferentes datas, ou coletado com distintos sensores (LEBOURGEOIS et al., 2008). Isso é geralmente importante para casos em que são gerados índices de vegetação, por exemplo (IQBAL; LUCIEER; BARRY, 2018). Esse processo é importante porque as câmeras normalmente utilizadas em VANTs não são calibradas, e vários erros radiométricos são incluídos nas imagens devido às características das câmeras e dos voos executados, como uso de ângulo de abertura pequeno nas câmeras (criando uma variação radial no ângulo de visada), e diferenças de iluminação (devido ao movimento do sol e outros fatores como presença de nuvens) (ADÃO et al., 2017; IQBAL; LUCIEER; BARRY, 2018).

Dentre os possíveis meios para a correção radiométrica das imagens, podem ser aplicados dois métodos: aquisição de parâmetros atmosféricos e de luminosidade no momento das tomadas das imagens; ou o uso de alvos de calibração radiométrica (PÁDUA et al., 2017). Esses alvos são posicionados em solo e têm sua reflectância mensurada (ou já conhecida), e a partir dos valores digitais desses nas imagens, pode-se fazer a transformação radiométrica de toda a cena capturada (IQBAL; LUCIEER; BARRY, 2018). Dentre os possíveis métodos de correção radiométrica de imagens obtidas por VANT podem ser utilizados espectrômetros para mensurar radiância de alvos (IQBAL; LUCIEER; BARRY, 2018), uso de alvos de calibração com valores conhecidos (KARYDAS et al., 2017), e ou uso de sensores a bordo que medem a irradiância solar no momento de coleta das imagens (SHEN et al., 2017).

1.2.3.6.2 Planejamento de voo

Atualmente, a maior parte dos voos com VANT para fins de mapeamento é planejada e controlada a partir de *softwares* específicos para esse fim (EISENBEISS; SAUERBIER, 2011; NEX; REMONDINO, 2014), porém com trajetória e parâmetros

definidos pelo piloto ou responsável pelo sistema de controle do veículo aéreo (EISENBEISS; SAUERBIER, 2011). Esses *softwares* podem ser simples aplicativos que podem ser instalados em celulares, ou sistemas mais avançados conectados à plataformas de antenas por exemplo (GIORDAN et al., 2018). Voos manuais normalmente não são recomendados para fim de mapeamento, porque a aquisição das imagens (principalmente em termos de sobreposição) resulta muito irregular (NEX; REMONDINO, 2014).

De maneira geral, segundo Eisenbeiss e Sauerbier (2011) o planejamento de voo envolve parâmetros como tipo elemento que será documentado, produtos almejados, tipo de sensor e VANT, restrições de voo (devido a legislação e segurança). Alguns parâmetros similares aos aplicados em voos para fotogrametria tradicional, como altura e velocidade de voo, e sobreposição lateral e longitudinal também precisam ser definidos (JORGE; INAMASU, 2014).

A definição de altura de voo e percentual de sobreposição, aliadas ao sensor selecionado (com suas respectivas propriedades de distância focal, tamanho de sensor, e outros) são as principais informações que interferem no processo fotogramétrico que será aplicado durante o processamento das imagens, pois esses afetam diretamente a escala e as propriedades estereoscópicas da cena. A escala, ou GSD (*ground sampling distance*) é definido como uma função da altura de voo, e das características de distância focal e tamanho do sensor utilizado (GRANSHAW, 2016; STANTON et al., 2017). É importante considerar que a altitude no ponto de decolagem não é constante no restante do terreno, portanto a escala das imagens também irá variar (WOLF; DEWITT; WILKINSON, 2014). Para minimizar esse efeito, muitos *softwares* de planejamento de voo apresentam a função de ajustar a altitude do voo com base em algum modelo de terreno disponível (como o SRTM, ASTER ou outros) (SENSEFLY LTD, 2014a).

A sobreposição entre imagens, na fotogrametria com aeronaves tripuladas, é importante tanto pela visão estereoscópica, como para a conexão entre as imagens, tanto entre linhas como no bloco todo (LINDER, 2016). É importante destacar que como os VANTs são muito sensíveis às variações de posição e atitude (ângulos) devido à ação do vento (ZHANG; XIONG; HAO, 2011), causando deslocamentos da posição do veículo aéreo e consequentemente variações na sobreposição das imagens. Devido a esse fator, em levantamentos fotogramétricos com VANT recomendam-se valores de sobreposição superiores aos utilizados na fotogrametria

com aeronaves tripuladas, porém dependendo da aplicação e características da área (NEX; REMONDINO, 2014; TORRES-SÁNCHEZ et al., 2018). Para VANTs os valores de sobreposição se encontram normalmente entre 40% até mais de 90% (DANDOIS; OLANO; ELLIS, 2015). Além das variações do VANT, dependendo da área que está sendo coberta, podem ocorrer variações na sobreposição devido a grandes variações no terreno ou presença de objetos altos, de forma que nesses casos recomenda-se aumentar a sobreposição no plano de voo (WOLF; DEWITT; WILKINSON, 2014).

A determinação da área que será sobrevoada, por sua vez compreende a área de interesse do projeto em si, e também a inclusão de uma margem extra para que a área de interesse seja recoberta por várias imagens (BARKÓCZI et al., 2018). Além disso, as bordas das imagens normalmente apresentam maiores distorções das lentes da câmera (IQBAL; LUCIEER; BARRY, 2018; LINDER, 2016; MLAMBO et al., 2017), principalmente devido a presença da distorção radial, que é definida como um componente intrínseco de distorção que ocorre em direção radial a partir do ponto principal (ANDRADE, 2003; LINDER, 2016; WOLF; DEWITT; WILKINSON, 2014). Dessa forma é recomendado que a área de interesse apresente recobrimento suficiente nas áreas centrais das imagens. Além da área que será fotografada, dependendo do tipo de VANT, ainda devem ser selecionadas áreas de decolagem e pouso, que em alguns casos incluem a necessidade de uma área livre de obstáculos, principalmente para o pouso de veículos aéreos de asas fixas (PÁDUA et al., 2017; SENSEFLY LTD, 2014a; SHEN et al., 2017).

Dadas as informações de área, parâmetros do voo e dados do sensor e VANT selecionados, é possível calcular informações como: tempo total de voo, número de voos (relativo à quantas baterias serão necessárias para completar o voo), total da distância percorrida, área coberta, número de linhas e espaçamento entre linhas de voo, distância entre fotos, entre outras (SENSEFLY LTD, 2014a).

De maneira geral, os voos realizados com VANT são menos impactados por condições atmosféricas em comparação à voos com aeronaves tripuladas ou mesmo satélites, pois normalmente não são afetados pela presença de nuvens (CHAO; CHEN, 2012; SALAMÍ; BARRADO; PASTOR, 2014). Apesar disso, os VANTs são afetados por chuva (KEDZIERSKI; WIERZBICKI, 2015), ventos muito fortes (DANDOIS; OLANO; ELLIS, 2015) e condições de iluminação (BONNET; LISEIN; LEJEUNE, 2017). De maneira geral se recomenda que os voos sejam realizados o mais próximo do meio dia solar (BONNET; LISEIN; LEJEUNE, 2017; PÁDUA et al.,

2017; SANKEY et al., 2017), pois quando o sol está em altitudes menores há a formação de maiores ângulos e de sombras, que são desaconselhadas porque podem causar a obstrução de objetos e feições (WOLF; DEWITT; WILKINSON, 2014).

Por fim, além dos elementos estritamente relacionados com o voo, é importante também fazer o planejamento dos pontos de controle (GCP), que apesar de serem opcionais no processamento, são imprescindíveis quando necessita-se do correto georreferenciamento dos produtos (NEX; REMONDINO, 2014). Por questões de ajustamento, são necessários no mínimo 3 GCP, e esses devem ser bem distribuídos sobre a área (BREDE et al., 2017; LINDER, 2016). É recomendado, porém, que se utilizem mais pontos para aumentar a exatidão do georreferenciamento (WOLF; DEWITT; WILKINSON, 2014). A quantidade de pontos, segundo Wolf, Dewitt e Wilkinson (2014), depende da área, formato, natureza da área levantada, exatidão necessária, além de equipamentos e pessoal disponíveis. O planejamento desses pontos é muito importante porque a exatidão dos produtos fotogramétricos é diretamente relacionada à exatidão dos GCPs (WOLF; DEWITT; WILKINSON, 2014). Além disso, o custo do levantamento dos GCP é substancial (GERKE; PRZYBILLA, 2016), tanto em termos de custo de equipamento como de tempo.

1.2.3.6.3 Processamento de dados: imagens

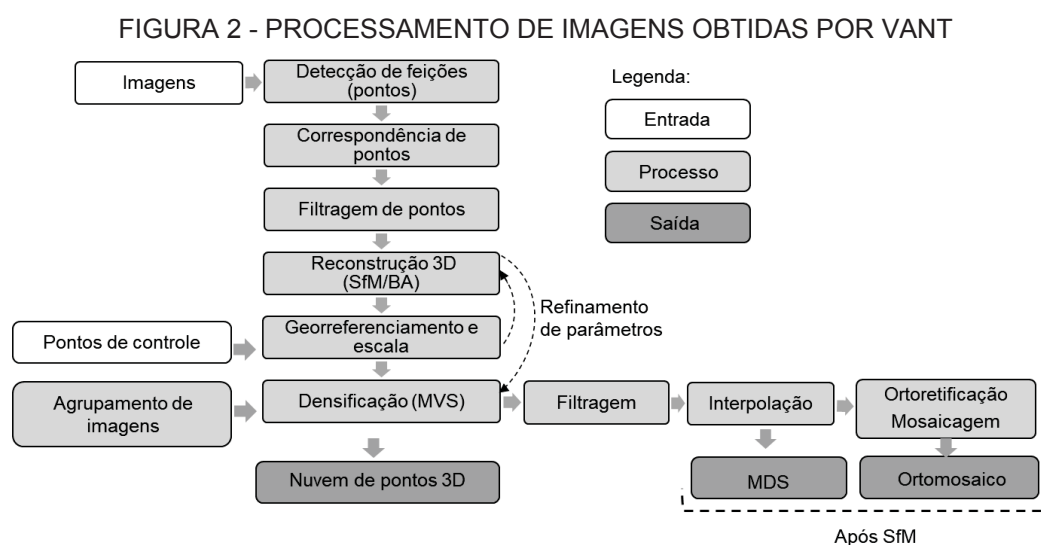
O processamento dos dados obtidos por sensores a bordo de VANTs depende de vários fatores, mas principalmente do tipo de sensor (câmera, radar, LiDAR ou outro). Nesse tópico foi abordado o processamento de imagens a partir de sensores passivos, pois foram o foco desse trabalho.

De maneira geral, o processamento de fotografias obtidas por VANT (ou até mesmo terrestres) para uso em geociências foi beneficiado de avanços em técnicas de visão computacional (*computer vision*) (COLOMINA; MOLINA, 2014; MICHELETTI; CHANDLER; LANE, 2015; NADOLINETS; LEVIN; AKHMEDOV, 2017). Nesse contexto se destacam as técnicas *Structure from Motion* (SfM) e *Multi View Stereo* (MVS) (CARRIVICK; SMITH; QUINCEY, 2016; MICHELETTI; CHANDLER; LANE, 2015), aliadas ao chamado *Bundle Adjustment* (BA) (em tradução, aerotriangulação por feixes de raio), considerado um dos pilares tanto da fotogrametria tradicional como da visão computacional (NADOLINETS; LEVIN; AKHMEDOV, 2017). Segundo Carrivick, Smith e Quincey (2016), apesar de na maioria das referências literárias

somente ser utilizado o termo SfM para o processamento de imagens, na realidade o processo normalmente abrange tanto as técnicas SfM como MVS.

O SfM foi desenvolvido por Ullman (1979) e tem aplicações em diversas áreas, as quais desenvolvem suas próprias definições para o termo. Em termos de fotogrametria, o SfM é definido como um processo que “resolve a auto-calibração das câmeras e geometria da cena de forma simultânea e automática, usando para isso pontos correspondentes nas imagens, e um ajustamento em bloco de forma redundante” (GRANSHAW, 2016, p. 244). Dessa forma, pode-se observar que a principal diferença entre as tradicionais técnicas de fotogrametria e o SfM é que no segundo, tanto a geometria interna, quanto a posição e orientação da câmera são determinadas automaticamente durante o processo (MICHELETTI; CHANDLER; LANE, 2015).

De maneira geral, a maioria dos sistemas baseados em SfM é designado para realizar de forma automática algumas etapas, destacadas na FIGURA 2 e detalhadas na sequência.



FONTE: Adaptado (SMITH; CARRIVICK; QUINCEY, 2015).

a) **Detecção de feições (*feature detection*):** é a primeira etapa necessária para a reconstrução da cena, e parte da identificação de pontos comuns em diferentes imagens, chamados de *keypoints* (pontos-chave) (CARRIVICK; SMITH; QUINCEY, 2016). Existem vários métodos para detecção de feições, porém nesse caso necessita-se de um método que consiga identificar pontos em imagens com diferentes posições de visada (e, portanto, diferentes escalas e iluminações). Dentre os

algoritmos possíveis para isso, o mais comum é o SIFT (*scale-invariant feature transform*) (CARRIVICK; SMITH; QUINCEY, 2016; MICHELETTI; CHANDLER; LANE, 2015; NADOLINETS; LEVIN; AKHMEDOV, 2017), desenvolvido por Lowe (2004). O SIFT primeiramente localiza os pontos em cada imagem e gera um histograma descritor para cada ponto (CARRIVICK; SMITH; QUINCEY, 2016).

b) Correspondência de pontos: nessa etapa, cada ponto (*keypoint*) detectado em cada imagem é comparado com os demais pontos entre as imagens vizinhas para que seja feita a correspondência entre eles (CARRIVICK; SMITH; QUINCEY, 2016; ZHANG; XIONG; HAO, 2011). Para tanto, podem ser utilizados vários métodos, como a distância Euclidiana do vizinho mais próximo (LOWE, 2004; SZELISKI, 2011).

c) Filtragem de pontos (identificação de pontos correspondentes consistentes): nessa etapa os *keypoints* são filtrados com o objetivo de reduzir observações errôneas (CARRIVICK; SMITH; QUINCEY, 2016). Esse processo é dado por diversas iterações com base em uma matriz construída entre duas imagens (CARRIVICK; SMITH; QUINCEY, 2016; GRANSHAW, 2016).

d) Estimativa da geometria 3D da cena (SfM): nessa etapa, são resolvidos, de forma simultânea, a estrutura 3D da cena, a posição e orientação das câmeras (orientação exterior), e normalmente os parâmetros de calibração das câmeras (orientação interior) (CARRIVICK; SMITH; QUINCEY, 2016), cujas etapas realmente caracterizam o SfM.

e) Georreferenciamento e escala: essa etapa realiza a transformação do espaço de coordenadas arbitrário da cena, para um sistema de coordenadas real, geralmente um sistema geodésico (CARRIVICK; SMITH; QUINCEY, 2016; GRANSHAW, 2016). Esse processo normalmente é realizado a partir da resolução de uma transformação linear com sete parâmetros, sendo eles três de translação, três de rotação e um de escala (CARRIVICK; SMITH; QUINCEY, 2016). Normalmente são utilizadas as coordenadas dos pontos de controle nesse processo (SZELISKI, 2011).

f) Refinamento de parâmetros: o refinamento de parâmetros de ajustamento trata da otimização dos parâmetros obtidos durante o BA, utilizando-se das coordenadas dos pontos de controle, e é uma opção oferecida em alguns *softwares* de processamento (CARRIVICK; SMITH; QUINCEY, 2016).

g) Agrupamento de imagens: essa é uma etapa opcional disponível em alguns *softwares*, em que antes da densificação, as imagens são agrupadas em *clusters* (grupos com características semelhantes) de forma a acelerar o processo

(CARRIVICK; SMITH; QUINCEY, 2016). Um dos algoritmos mais comuns para isso é o CMVS (*Clustering Views for Multi-view Stereo*) (CARRIVICK; SMITH; QUINCEY, 2016; GRANSHAW, 2016).

h) Densificação: nessa etapa, são utilizados algoritmos de MVS para densificar a nuvem de pontos esparsa criada durante o BA, permitindo, assim, a completa reconstrução da cena em 3D (CARRIVICK; SMITH; QUINCEY, 2016; SZELISKI, 2011). Existem diversos algoritmos MVS e, dentre eles, um dos mais populares é o PMVS (CARRIVICK; SMITH; QUINCEY, 2016; SHAO et al., 2016), cujo método se destaca por produzir pontos de correspondência de forma mais densa do que a detecção dos métodos baseados em feições, e apresenta um resultado com distribuição regular (SHAO et al., 2016).

i) Filtragem/classificação: a classificação da nuvem de pontos é um processo que geralmente se aplica para separar os pontos que são correspondentes ao solo, para geração de modelo digital do terreno (MDT), ou para classificar vegetação para fins de cálculo de biomassa e outros (SMITH; CARRIVICK; QUINCEY, 2015). Essa filtragem também permite a exclusão de *outliers*, que podem provocar erros nas análises subsequentes, assim como pode ser voltada para a remoção de dados redundantes e, conseqüentemente, diminuição dos arquivos (CARRIVICK; SMITH; QUINCEY, 2016). Essa filtragem pode ser realizada a partir de vários algoritmos, muitos dos quais desenvolvidos originalmente para dados Laser, ou em alguns casos executada de forma manual (CARRIVICK; SMITH; QUINCEY, 2016).

j) Interpolação: a partir da nuvem de pontos gerada pelo processamento descrito é possível a obtenção de modelos digitais de elevação (MDE), geralmente apresentados em forma 2D a partir de MDS ou MDT (CARRIVICK; SMITH; QUINCEY, 2016). Os MDE são representações das elevações do terreno em uma malha de distribuição regular (WOLF; DEWITT; WILKINSON, 2014), e portanto é necessária a utilização de interpoladores para fechar as falhas existentes nas nuvens de pontos gerados durante o processamento (CARRIVICK; SMITH; QUINCEY, 2016; SMITH; CARRIVICK; QUINCEY, 2015; WHITEHEAD; HUGENHOLTZ, 2014). Possíveis interpoladores são o Inverso da Distância Ponderada, Krigagem ordinária, e outros (GRANSHAW, 2016; SMITH; CARRIVICK; QUINCEY, 2015).

k) Ortorretificação e mosaicagem: o processo de ortorretificação realiza a remoção de deformações causadas pela inclinação das imagens e influência do relevo, utilizando, para tanto, um MDE (GRANSHAW, 2016; WOLF; DEWITT;

WILKINSON, 2014). Após o processo de ortorretificação, as imagens normalmente são mescladas e formam um produto único chamado de ortomosaico ou ortofoto, durante o processo de mosaicagem (WHITEHEAD; HUGENHOLTZ, 2014). Numa ortofoto, os objetos representados estão em sua verdadeira posição ortográfica (ortogonalmente, ou seja, com os ângulos ajustados), de forma que podem ser feitas medições de ângulos, distâncias, posições e áreas diretamente nelas de forma correta (WOLF; DEWITT; WILKINSON, 2014). A qualidade do ortomosaico porém depende da exatidão do MDE utilizado, e quando se consideram objetos acima do terreno (MDS), o mosaico pode apresentar distorções e aparência irregular (WHITEHEAD; HUGENHOLTZ, 2014; WOLF; DEWITT; WILKINSON, 2014).

1.2.3.6.4 Aplicativos computacionais

Existem dois grupos de aplicativos computacionais importantes em relação à aquisição de dados com VANTs. O primeiro grupo se refere aos *softwares* de planejamento e controle de voo, que permitem um simplificado manuseio dos VANTs em termos de voo (NEX; REMONDINO, 2014). No caso dos *softwares* de planejamento de voo, existem diversos aplicativos disponíveis, dentre eles *softwares* proprietários e de código aberto, podendo-se citar, por exemplo, Drone2Map, Pix4D capture, DJI Go e eMotion no primeiro grupo, e Opendronemap, Drone Deploy, Mission Planner e QGroundControl no segundo grupo (SANTAMARINA-CAMPOS et al., 2018). Com relação a escolha do *software* de planejamento de voo, Amirebrahimi et al. (2018) realizaram um estudo com usuários de VANT na Austrália e Nova Zelândia e observaram que os dois mais utilizados eram, em sequência, Pix4D capture e DJI Go. Apesar disso, Amirebrahimi et al. (2018), observaram que para a maioria dos usuários a escolha do *software* era principalmente baseada na correlação com o VANT utilizado (por exemplo, quando a empresa desenvolvedora do VANT comercializa juntamente um software de planejamento, como no caso do eMotion e DJI Go), e que ainda muitos usuários não utilizam um *software* específico, baseando-se ferramentas como Google Earth para o planejamento.

Em casos em que o VANT pode ser utilizado com diversos softwares, um ponto importante a ser considerado é a capacidade de comunicação com diversos sistemas operacionais grupo (SANTAMARINA-CAMPOS et al., 2018). Outra questão importante é a presença de certas ferramentas, como as que permitem a realização

de ajustes na altura do voo em função de alterações na elevação do terreno, de forma que o GSD e a sobreposição das imagens seja aproximadamente constante (CHABOT; BIRD, 2015), que estão presentes, por exemplo, no eMotion e Maps Made Easy (DRONES MADE EASY, 2018; SENSEFLY LTD, 2014a).

Já o segundo grupo compreende os *softwares* de processamento de imagens, que inclui plataformas que realizam todas as etapas do processamento de forma praticamente automatizada, e que juntamente com desenvolvimento das técnicas de visão computacional, foram importantes no processo de disseminação dos dados oriundos de imagens VANT (MICHELETTI; CHANDLER; LANE, 2015). Existem vários tipos de softwares de processamento de imagens, como os de código aberto ou comerciais, os que realizam processamento em nuvem (*cloud computing*) ou no próprio computador, os que foram criados para uso em fotogrametria tradicional ou criados para uso com VANT e aplicações SfM, entre outros (GRANSHAW, 2016; MICHELETTI; CHANDLER; LANE, 2015; NADOLINETS; LEVIN; AKHMEDOV, 2017; SONA et al., 2014). Existem também *softwares* que são somente visualizadores de nuvens de pontos, que podem ser úteis, principalmente na integração de nuvens de diferentes sensores (CARRIVICK; SMITH; QUINCEY, 2016).

Dentre os *softwares* comerciais, podem-se citar Agisoft Photoscan, Pix4D, SimActive, APS Mensi, Autodesk ReCap, DroneDeploy (*cloud computing*) e DroneMapper (*cloud computing*), enquanto que dentre os de código aberto ou gratuitos podem-se citar o Visual SFM, Bundler, PMVS/CMVS, MicMac, Photosynth (*cloud computing*) e 123-D Catch (*cloud computing*) (CARRIVICK; SMITH; QUINCEY, 2016; ELTNER et al., 2016; NADOLINETS; LEVIN; AKHMEDOV, 2017). Em um estudo publicado por (ELTNER et al., 2016), o Agisoft Photoscan seguido por Bundler foram os *softwares* mais observados no processamento de imagens VANT, enquanto que em Amirebrahimi et al. (2018), observou-se que o *software* de processamento mais utilizado foi o Pix4D seguido pelo Agisoft Photoscan.

As estratégias e algoritmos de processamento de cada *software* são variadas, e nem sempre abertamente divulgadas no caso dos aplicativos proprietários, e, portanto, com capacidades distintas. Alguns dos pacotes mais simples, por exemplo, integram somente modelos simples de câmeras, e não permitem a inclusão de CGPs na etapa de ajustamento, como é o caso do VSfM e Bundler (ELTNER; SCHNEIDER, 2015). Outro ponto importante a ser verificado na escolha de um *software* é em relação aos recursos computacionais que este pode acessar, pois o tempo de processamento

para muitas imagens pode ser bastante elevado. Muitos pacotes, incluindo Pix4D e Agisoft Photoscan, apresentam a vantagem de serem compatíveis com *OpenCL*, que permite utilizar um GPU (*Graphics Processing Unit*) durante o processamento, não apenas para visualização, tornando o processo mais rápido (VERHOEVEN, 2011).

Considerados os *softwares* mais utilizados, ambos Agisoft Photoscan e Pix4D apresentam resultados satisfatórios e semelhantes, porém com vantagens e desvantagens. O Agisoft Photoscan normalmente é capaz de identificar um maior número pontos de correspondência (*keypoints*) do que o Pix4D, porém os pontos identificados no Pix4D são encontrados em mais imagens, portanto podem ser mais confiáveis (SONA et al., 2014). Normalmente, se observa que o Agisoft Photoscan leva mais tempo para executar algumas tarefas em comparação ao Pix4D, porém os resultados desse primeiro são geralmente mais acurados (RODRIGUES et al., 2016). Já, segundo Shen et al. (2017), o Pix4D pode ser uma melhor escolha para trabalhar com sensores multiespectrais, porque já apresenta um processo integrado e automatizado para esse tipo de câmera, enquanto que outros *softwares*, como Agisoft Photoscan, esse processo é mais difícil. Corroborar para isso o fato de que o Agisoft Photoscan passou a apresentar uma ferramenta de calibração radiométrica apenas a partir da versão 1.4.0, lançada em dezembro de 2017 (AGISOFT LLC, 2018), enquanto que Pix4D apresenta essa funcionalidade desde a versão 1.4.28, lançada em abril de 2015 (PIX4D, 2018a).

1.2.3.7 Vantagens e limitações

De maneira geral, as principais vantagens do uso de VANTs para aplicações em sensoriamento remoto estão ligadas ao custo benefício em relação aos produtos gerados (PÁDUA et al., 2017; WHITEHEAD; HUGENHOLTZ, 2014), e à flexibilidade deles, tanto pela capacidade de incorporação de diversos sensores (PÁDUA et al., 2017; TANG; SHAO, 2015), quanto na liberdade de data para coleta de dados (ANDERSON; GASTON, 2013; TOTH; JÓŹKÓW, 2016). Os custos baixos se referem tanto ao custo dos veículos aéreos e dos sensores embarcados (PÁDUA et al., 2017; TOTH; JÓŹKÓW, 2016), quanto da necessidade de poucas pessoas envolvidas e do baixo grau de especialização e treinamento dos participantes, devido à disponibilidade de *softwares* que automatizem grande parte do processo (MLAMBO et al., 2017). Ao mesmo tempo, são obtidos produtos como ortomosaicos, nuvens de pontos e modelos

de elevação com alta resolução (ANDERSON; GASTON, 2013; PÁDUA et al., 2017; TOTH; JÓŽKÓW, 2016), antes obtidos somente por métodos terrestres (TLS ou estação total - TS), cujo custo e tempo de coleta é muito mais elevado (TOTH; JÓŽKÓW, 2016).

Além disso, conforme destacado anteriormente, a disseminação dos dados de VANT em sensoriamento remoto e aplicações civis em geral se deu também pelo desenvolvimento de técnicas de processamento de forma praticamente automatizada, sem necessidade de alto grau de treinamento para o manuseio dos dados (MICHELETTI; CHANDLER; LANE, 2015; MLAMBO et al., 2017). Mais detalhes das vantagens do uso de VANTs para sensoriamento remoto estão apresentados na TABELA 5.

TABELA 5 - VANTAGENS DA UTILIZAÇÃO DE VANTS PARA SENSORIAMENTO REMOTO

Etapas	Vantagem
Equipamento	Baixo custo (variável com o tipo)
Coleta de dados	Baixo custo, principalmente para projetos pequenos e dependendo do tipo de VANT Rápida comparada aos meios terrestres (TL e TS) Acesso a áreas difíceis (em relação aos sistemas terrestres) e perigosas (desastres naturais, incêndios) Resolução espacial alta comparada com outras técnicas de SR (satélite, fotografia aérea) Alta repetibilidade e flexibilidade (resolução temporal) Capacidade de carregar vários tipos de sensores, com restrições de tamanho (resolução espectral)
Voo	Automatizado Fácil transportar e montar Pouco afetado por nuvens, e ventos (dependendo do tipo) Risco operacional baixo
Processamento	<i>Softwares</i> automatizados que exigem pouca interação do usuário Aceita vários tipos de câmeras (mesmo não calibradas) Gera nuvem de pontos com coloração e maior densidade (comparadas aos sistemas LiDAR)

FONTE: Adaptado (ADÃO et al., 2017; ANDERSON; GASTON, 2013; BREDE et al., 2017; MANFREDI et al., 2018; MICHELETTI; CHANDLER; LANE, 2015; MLAMBO et al., 2017; NADOLINETS; LEVIN; AKHMEDOV, 2017; SHAO et al., 2016; TANG; SHAO, 2015; TOTH; JÓŽKÓW, 2016; VASTERLING; MEYER, 2013; WHITEHEAD et al., 2014; WHITEHEAD; HUGENHOLTZ, 2014).

Na TABELA 6 estão apresentadas algumas desvantagens e limitações do uso dos VANTs. Nessas tabelas, e na revisão em geral, foram focados principalmente os VANTs com base em sensores passivos (câmeras), assim como relacionados aos VANTs de tamanho pequeno, normalmente utilizados para fins civis.

TABELA 6 - LIMITAÇÕES DA UTILIZAÇÃO DE VANTS PARA SENSORIAMENTO REMOTO

Etapa	Limitações
Voo	Cobertura pequena comparada aos sensores aéreos (dependendo do tipo), devido a tamanho do sensor, restrições de carga (combustível) e legislação Afetado por chuva, ventos fortes (dependendo do tipo) e luminosidade ¹ Problemas de processamento devido a presença de sombras Necessidade de coleta de dados com alta redundância devido ao método de processamento Restrição para voos em certas áreas e condições (de altura, tamanho do VANT, tipo de visada, e outros), dependendo do país ou outra legislação local Suscetibilidade a acidentes devido aos fatores como vento, e risco de dano no contato com solo
Processamento	Dificuldade de reconstrução em áreas homogêneas Participação limitada do usuário, dificultando identificação de fontes de erros Devido à qualidade dos sensores e a estabilidade de voo, a geometria das imagens geralmente é inferior Qualidade e extensão dos produtos só podem ser verificados após processamento (não no momento da coleta) Grandes bases de dados, exigem grande capacidade computacional e tempo de processamento Sensores multi e hiperespectrais podem exigir etapas a mais de processamento (calibração radiométrica)
Equipamento Sensor	Necessidade de uso de sensores imageadores e de navegação com tamanho reduzido (menor precisão, maiores erros associados) Geralmente não permitem penetração da radiação na vegetação, e, portanto, não permitem a obtenção de modelos do terreno ¹
Pós-processamento	Limitação da aplicação dos resultados em análises espectrais devido à baixa qualidade radiométrica e diferenças de iluminação na tomada de imagens Dificuldade da aplicação de certas técnicas de classificação devido ao alto nível de detalhe (altíssima resolução espacial)
Exatidão posicional	Depende da presença de pontos de controle, ou sensores com correção direta com custo elevado

¹ para sensores passivos;

FONTE: Adaptado (ADÃO et al., 2017; ANDERSON; GASTON, 2013; CARRIVICK; SMITH; QUINCEY, 2016; FLOREANO; WOOD, 2015; MANFREDI et al., 2018; MICHELETTI; CHANDLER; LANE, 2015; MLAMBO et al., 2017; NADOLINETS; LEVIN; AKHMEDOV, 2017; SHEN et al., 2017; TANG; SHAO, 2015; VASTERLING; MEYER, 2013; WATTS; AMBROSIA; HINKLEY, 2012; WHITEHEAD et al., 2014; WHITEHEAD; HUGENHOLTZ, 2014)

Dentre as principais limitações, em muitos casos estas são relacionadas aos mesmos fatores ponderados como vantagens. Por exemplo, o reduzido tamanho dos VANTS e dos sensores permitiu a comercialização desses veículos com preço baixo e facilidade de uso, porém a redução do tamanho resulta em menor cobertura do voo, limitando a eficiência do uso de VANTS em áreas pequenas ou médias (ANDERSON; GASTON, 2013; PÁDUA et al., 2017). Isso se refere tanto a área coberta por cada imagem, como pelo tamanho das baterias e outros fatores.

Também, devido ao tamanho dos sensores (tanto imageadores como do sistema de navegação), estes apresentam menor precisão, e, portanto, aumentam a dificuldade do processamento, a localização não é precisa e a geometria das imagens apresenta muitas distorções (GERKE; PRZYBILLA, 2016; MANFREDI et al., 2018;

WHITEHEAD; HUGENHOLTZ, 2014). Devido à baixa precisão dos sensores de navegação (GPS e IMU) embarcados, a exatidão das coordenadas de localização é dependente do uso de pontos de controle, em distribuição e quantidade adequadas, aumentando o custo e tempo de coleta dos dados (ELTNER et al., 2016; MANFREDA et al., 2018; WHITEHEAD; HUGENHOLTZ, 2014).

Devido ao método de processamento e às variações da coleta das imagens, é necessária a coleta de dados com alta redundância (CARRIVICK; SMITH; QUINCEY, 2016; MICHELETTI; CHANDLER; LANE, 2015), o que gera uma base de dados grande (ADÃO et al., 2017; PÁDUA et al., 2017), que necessita longo tempo de processamento, assim como alta capacidade computacional (CARRIVICK; SMITH; QUINCEY, 2016; MANFREDA et al., 2018; PÁDUA et al., 2017). Dependendo do tipo de sensor usado, podem ainda ser necessárias outras etapas de processamento, como a calibração radiométrica de sensores (MANFREDA et al., 2018; SHEN et al., 2017). Ainda, em função da limitação do tamanho de sensores, da influência de fatores como luminosidade e sombras, e do nível de detalhamento obtido, a aplicação dos produtos derivados de VANTs em algumas técnicas tradicionais de sensoriamento remoto, como classificações por pixel e análises espectrais, pode ser mais difícil e exigir um longo tempo de processamento (WHITEHEAD; HUGENHOLTZ, 2014).

Ainda, é importante considerar as limitações do uso de VANTs de acordo com a legislação vigente, sendo que essas podem afetar a cobertura de dados devido às limitações de altura de voo e visada, ou mesmo restringir acesso à algumas áreas, como próximo à aeroportos (CARRIVICK; SMITH; QUINCEY, 2016; WATTS; AMBROSIA; HINKLEY, 2012).

1.2.3.8 Estado da arte do uso de VANTs em aplicações florestais

O uso de dados de VANTs tem se tornado cada vez mais frequente nos últimos anos (COLOMINA; MOLINA, 2014; WHITEHEAD; HUGENHOLTZ, 2014). Diversos são os usos desses veículos, tanto para fins de sensoriamento remoto aplicados à usos agrícolas, ambientais, florestais, como para áreas de planejamento urbano, construção civil e arqueologia, e outras (SALAMÍ; BARRADO; PASTOR, 2014; SHAHBAZI; THÉAU; MÉNARD, 2014; WHITEHEAD; HUGENHOLTZ, 2014). Na área florestal, podem ser encontradas diversas aplicações, dentre elas as focadas na

estrutura da floresta, tanto em nível de área (parcela) como em nível de árvore individual, conforme a TABELA 7.

Observa-se que as estimativas de alturas e até de volume e biomassa são possíveis a partir de imagens derivadas de VANT, porém esses estudos ainda são limitados à áreas com vegetação aberta (BIRDAL; AVDAN; TÜRK, 2017; CUNLIFFE; BRAZIER; ANDERSON, 2016; JENSEN; MATHEWS, 2016; WALLACE et al., 2016), florestas temperadas (DANDOIS; ELLIS, 2013; DANDOIS; OLANO; ELLIS, 2015; PULITI et al., 2015), e ou à disponibilidade de um modelo de terreno de outra fonte (DANDOIS; OLANO; ELLIS, 2015; LISEIN et al., 2013; MESSINGER; ASNER; SILMAN, 2016). Dentre esses trabalhos, o único em áreas tropicais é o de Messinger, Asner e Silman (2016), realizado em floresta amazônica.

TABELA 7 - ESTADO DA ARTE DE TRABALHOS UTILIZANDO VANTS PARA ESTIMATIVA DE PARÂMETROS ESTRUTURAIS DE FLORESTAS

Nível	Aplicação	Fontes
Área	Alturas, volumes, biomassa e carbono	(DANDOIS; ELLIS, 2013; DANDOIS; OLANO; ELLIS, 2015; JENSEN; MATHEWS, 2016; MESSINGER; ASNER; SILMAN, 2016; PULITI et al., 2015)
	Parâmetros de diversidade	(ZHANG et al., 2016)
	Fechamento da copa e índice de área foliar	(CHIANUCCI et al., 2016)
	Crescimento da floresta (m ³ /ha)	(GIANNETTI et al., 2018)
Individual	Deteção de árvore individual	(BIRDAL; AVDAN; TÜRK, 2017; BONNET; LISEIN; LEJEUNE, 2017; GOODBODY et al., 2017; GUERRA-HERNÁNDEZ et al., 2016, 2017; MOHAN et al., 2017; RUZA et al., 2017; SUROVÝ; YOSHIMOTO; PANAGIOTIDIS, 2016)
	Altura	(GUERRA-HERNÁNDEZ et al., 2017; LISEIN et al., 2013; PANAGIOTIDIS et al., 2016; WALLACE et al., 2016)
	Diâmetro de copa	(GUERRA-HERNÁNDEZ et al., 2016, 2017; PANAGIOTIDIS et al., 2016)
	Carbono e biomassa	(CUNLIFFE; BRAZIER; ANDERSON, 2016)
	Crescimento	(DEMPEWOLF et al., 2017; GOODBODY et al., 2017)

FONTE: A autora (2018)

Já os trabalhos com foco na detecção de árvores não são necessariamente dependentes de um modelo do terreno, podendo ser desenvolvidos apenas com o ortomosaico (BONNET; LISEIN; LEJEUNE, 2017; RUZA et al., 2017). Da mesma forma, é possível análises de crescimento sem uso do MDT, apenas pela diferença do MDS em dois períodos (DEMPEWOLF et al., 2017). De maneira geral, é também interessante observar a grande gama de trabalhos com enfoque em árvores individuais.

Além da estrutura da floresta, outros trabalhos encontrados se referem à monitoramentos da floresta, detecção de danos causados por pragas e doenças, estimativa de parâmetros de diversidade da floresta, e até classificação de certas espécies arbóreas (TANG; SHAO, 2015; TORRESAN et al., 2017). A maior parte dos casos em estudos com VANT para aplicações florestais na Europa encontrados em revisão por Torresan et al. (2017) utilizaram drones do tipo asa rotatória (cerca de 57%), câmeras RGB e multiespectrais (40 e 35%), e com aplicações voltadas para obtenção de variáveis dendrométricas e saúde da floresta (36 e 21%). Ainda, grande parte das câmeras com banda NIR em estudos com VANT encontrados até o momento foram adaptadas de câmeras RGB (SALAMÍ; BARRADO; PASTOR, 2014; TORRESAN et al., 2017).

De acordo com Salamí, Barrado e Pastor (2014), também é comum que, em aplicações envolvendo vegetação, sejam utilizados índices baseados na matemática de bandas (como NDVI, EVI e outros), pois estes auxiliam na diferenciação de aspectos da vegetação e, na maior parte dos casos, esses índices são baseados na banda NIR (PÁDUA et al., 2017; SALAMÍ; BARRADO; PASTOR, 2014). De maneira geral, para cálculo de parâmetros como biomassa e carbono recomenda-se que sejam utilizados índices com base em bandas além do espectro visível (composto pelas cores RGB), como por exemplo as bandas NIR e Red-edge (PÁDUA et al., 2017).

Dentre as técnicas que são aplicadas a esses dados florestais, podem ser citadas segmentações (PÁDUA et al., 2017; SALAMÍ; BARRADO; PASTOR, 2014), aplicadas inclusive nos resultados dos índices de bandas (PÁDUA et al., 2017), utilizadas principalmente para detecção de árvores e delineamento de copas (TORRESAN et al., 2017). As segmentações podem ser de diversos tipos, como a segmentação de bacias (NÄSI et al., 2015), ou baseadas em resposta espectral (ALONZO et al., 2018; GUERRA-HERNÁNDEZ et al., 2016). Outro método comum para detecção de árvores é o uso do algoritmo de *Local Maxima* (BONNET; LISEIN; LEJEUNE, 2017; MOHAN et al., 2017; PANAGIOTIDIS et al., 2016). Para cálculos de alturas, volumes e biomassa existem vários métodos, como extração de métricas da nuvem de pontos baseados em alturas e em alguns casos métricas espectrais (GIANNETTI et al., 2018; LISEIN et al., 2013; PULITI et al., 2015), aplicadas em métodos de estimativa em nível de parcelas (OTA et al., 2017) e também de árvore individual (BONNET; LISEIN; LEJEUNE, 2017).

CAPÍTULO 2: PROCESSAMENTO DE DADOS OBTIDOS POR VANT PARA SUBSIDIAR INVENTÁRIO FLORESTAL

2.1 INTRODUÇÃO

Os inventários florestais podem ser caracterizados como a principal fonte de informações sobre uma determinada área composta de florestas (PÉLLICO NETTO; BRENA, 1997), pois permitem caracterizar variáveis qualitativas e quantitativas da floresta, além de inferir acerca do potencial produtivo de uma determinada área (SCOLFORO; MELLO, 2006). Existem diversos métodos que podem ser aplicados nos inventários, porém de maneira geral, pode-se dizer que as técnicas de amostragem são mais comuns em comparação com o censo, visto que a enumeração total dos indivíduos de uma área é uma tarefa muito onerosa, justificada apenas em alguns casos, como áreas reduzidas (SANQUETTA et al., 2014). As técnicas de amostragem permitem a obtenção de informações necessárias em um menor tempo e custo (BONHAM, 2013; SOARES; NETO; SOUZA, 2011).

Apesar das vantagens das técnicas de amostragem, essas também são onerosas e apresentam erros, que, de maneira geral, quando se aplicam limites de erros mais rigorosos, o tempo e custo do inventário são maiores (SANQUETTA et al., 2014), sendo que esses também são influenciados pelas variáveis coletadas e características da área (KERSHAW JR. et al., 2017; SANQUETTA et al., 2014). Ainda, é importante destacar que os inventários têm abrangência limitada, mesmo quando aplicados a estratos, pois estes podem ser de difícil delimitação se baseado apenas em informações terrestres (KERSHAW JR. et al., 2017; SANQUETTA et al., 2014). Devido a essas limitações, é comum o uso de informações provenientes de sensoriamento remoto (SR) em diversas aplicações no âmbito dos inventários florestais (KERSHAW JR. et al., 2017; WEST, 2015). Esses dados podem ser provenientes de sensores como câmeras, radares ou *laser scanners*, embarcados em plataformas como aeronaves tripuladas e VANTs, satélites ou equipamentos terrestres (HYYPÄ et al., 2015; WHITE et al., 2016), entre outros.

Nesse contexto, o uso de Veículos Aéreos Não Tripulados (VANTs) tem se destacado nos últimos anos. Os VANTs apresentam diversas características que promovem seu uso, entre elas está o baixo custo de aquisição de dados em comparação com outras plataformas de SR para produtos com resoluções similares

(TOTH; JÓŽKÓW, 2016; WHITEHEAD; HUGENHOLTZ, 2014). Esse custo porém é função do tamanho da área, sendo que, em geral, o uso de VANTs é mais eficiente em áreas pequenas ou médias (ANDERSON; GASTON, 2013; PÁDUA et al., 2017). Os VANTs também se destacam por permitirem obtenção de dados com alta resolução espacial e temporal, permitindo o seu uso em análises com alto grau de detalhamento e em datas específicas (ANDERSON; GASTON, 2013; PÁDUA et al., 2017; TOTH; JÓŽKÓW, 2016). Outra vantagem do uso de VANTs é a capacidade de seleção de sensores em diversas faixas do espectro eletromagnético (PÁDUA et al., 2017; TANG; SHAO, 2015; WHITEHEAD et al., 2014), de forma que os VANTs podem ser adaptadas à diversas aplicações.

Apesar da flexibilidade de sensores, as aplicações até o presente momento foram principalmente focadas em sensores passivos, especialmente contendo as faixas do espectro visível (RGB), ou de bandas na faixa do infravermelho (SHAHBAZI; THÉAU; MÉNARD, 2014; TORRESAN et al., 2017). A utilização de sensores passivos está aliada a outro fato que promoveu o uso dos VANTs, que é o avanço nos métodos de processamento de imagens, com a aplicação conjunta de técnicas como *Structure from Motion* (SfM) e *Multi View Stereo* (MVS) (CARRIVICK; SMITH; QUINCEY, 2016). O SfM é uma técnica aplicada em diversas áreas, sendo que em relação ao processamento de imagens é definida como um processo que “resolve a autocalibração das câmeras e geometria da cena de forma simultânea e automática, usando para isso pontos correspondentes nas imagens, e ajustamento em bloco de forma redundante” (GRANSHAW, 2016, p. 244). Além disso, o surgimento de *softwares* de tratamento de imagens baseados no SfM permitiu a disseminação desse tipo de processamento de forma mais ampla, principalmente porque usuário não precisa ter conhecimento avançado para sua utilização (CARRIVICK; SMITH; QUINCEY, 2016).

Dadas as características vantajosas dos VANTs e das novas técnicas de processamento, diversos estudos com dados VANT surgiram nos últimos anos com aplicações florestais. Dentre essas aplicações, podem-se citar análises em nível geral, como de mapeamentos de florestas e tipos de florestas (CUNLIFFE; BRAZIER; ANDERSON, 2016), incêndios florestais (FERNÁNDEZ-GUISURAGA et al., 2018), ocorrências de pragas (DASH et al., 2017; NÄSI et al., 2018), análises de diversidade (clareiras) (GETZIN; NUSKE; WIEGAND, 2014), identificação de certas espécies (FRANKLIN; AHMED, 2017; LISEIN et al., 2015), entre outros. Porém, os dados VANT

são capazes também de aplicações em nível da estrutura da floresta, como a detecção de árvores individuais (BONNET; LISEIN; LEJEUNE, 2017; GOODBODY et al., 2017; PANAGIOTIDIS et al., 2016), e estimativas de altura, diâmetro de copa, volumes, biomassa e crescimento, tanto para árvore individual como para estimativas por parcela (DANDOIS; ELLIS, 2013; GIANNETTI et al., 2018; GOODBODY et al., 2017; PANAGIOTIDIS et al., 2016; ZHANG et al., 2016). Apesar da existência de vários trabalhos sobre estes temas, esses são bastante limitados em algumas circunstâncias, como por exemplo, a maior parte desses é desenvolvido em florestas temperadas ou em áreas abertas que permitem a visualização do terreno, ou dependem da existência de um modelo de terreno de outra fonte (derivado de dados LiDAR, por exemplo) para cálculo de alturas e volumes, sendo que a oclusão do terreno em áreas florestais é uma das maiores limitações do uso de VANTs (TOMAŠTÍK et al., 2017).

Ainda, é importante destacar que os resultados desses estudos são muito variáveis, e isso se dá tanto por características das áreas, como em função de parâmetros de voo e equipamentos utilizados (TOMAŠTÍK et al., 2017). Quanto a área selecionada, observa-se que em florestas densas é difícil a identificação de pontos de ligação (*keypoints*) (BEMIS et al., 2014), devido ao diferente aspecto do arranjo das folhas em diferentes pontos de visada (ELTNER et al., 2016). O baixo número de *keypoints* dificulta o processamento das imagens, pois esses pontos são os principais elementos utilizados no ajustamento SfM. As características da superfície também afetam a quantidade de pontos criados na etapa de densificação da nuvem de pontos (DANDOIS; ELLIS, 2013), causando diferenças na caracterização de objetos. Da mesma forma, parâmetros como declividade do terreno e proporção de árvores afetam a precisão horizontal e vertical dos produtos derivados das imagens (TOMAŠTÍK et al., 2017) e a capacidade de penetração de pontos no interior da floresta (IQBAL et al., 2018).

Como as características da floresta, como declividade do terreno e densidade de árvores, são inerentes a área, e a seleção de equipamentos é bastante limitada em função do orçamento disponível, os principais elementos que podem ser controlados e que afetam a modelagem de florestas com VANTs são características de voo como altura e taxas de recobrimento. Para áreas de floresta ou projetos com objetivos de obtenção de parâmetros 3D, de maneira geral recomendam-se altos graus de recobrimento e *grid* de aquisição duplo (DANDOIS; OLANO; ELLIS, 2015; PIX4D,

2018b), além da utilização de uma área de voo extensa para evitar bordas (DANDOIS; ELLIS, 2013). Outros parâmetros importantes são a luminosidade, porque de acordo com a posição do sol podem ocorrer muitas sombras e, conseqüentemente, a oclusão de áreas nas imagens (DANDOIS; OLANO; ELLIS, 2015; IQBAL et al., 2018), e a inclusão de pontos de controle em número e posicionamento adequados, visto que o correto georreferenciamento das imagens em um sistema de coordenadas métrico é importante para a mensuração de variáveis ali selecionadas (TOMAŠTÍK et al., 2017). Dessa forma, é importante que seja feito um bom planejamento para coleta de imagens com VANT em áreas florestadas, e que os produtos gerados a partir desses sejam analisados quanto à sua exatidão antes da mensuração de subseqüentes variáveis.

2.2 OBJETIVOS

O objetivo principal deste capítulo foi processar os dados obtidos com o VANT. Especificamente, os objetivos foram:

- Caracterizar os talhões selecionados com base nas informações levantadas pelo inventário de campo;
- Caracterizar os métodos de coleta de dados VANT;
- Analisar propriedades e precisões de produtos obtidos a partir das imagens aéreas VANT; e
- Analisar a possibilidade do uso conjunto de dados VANT e LiDAR.

2.3 MATERIAL E MÉTODOS

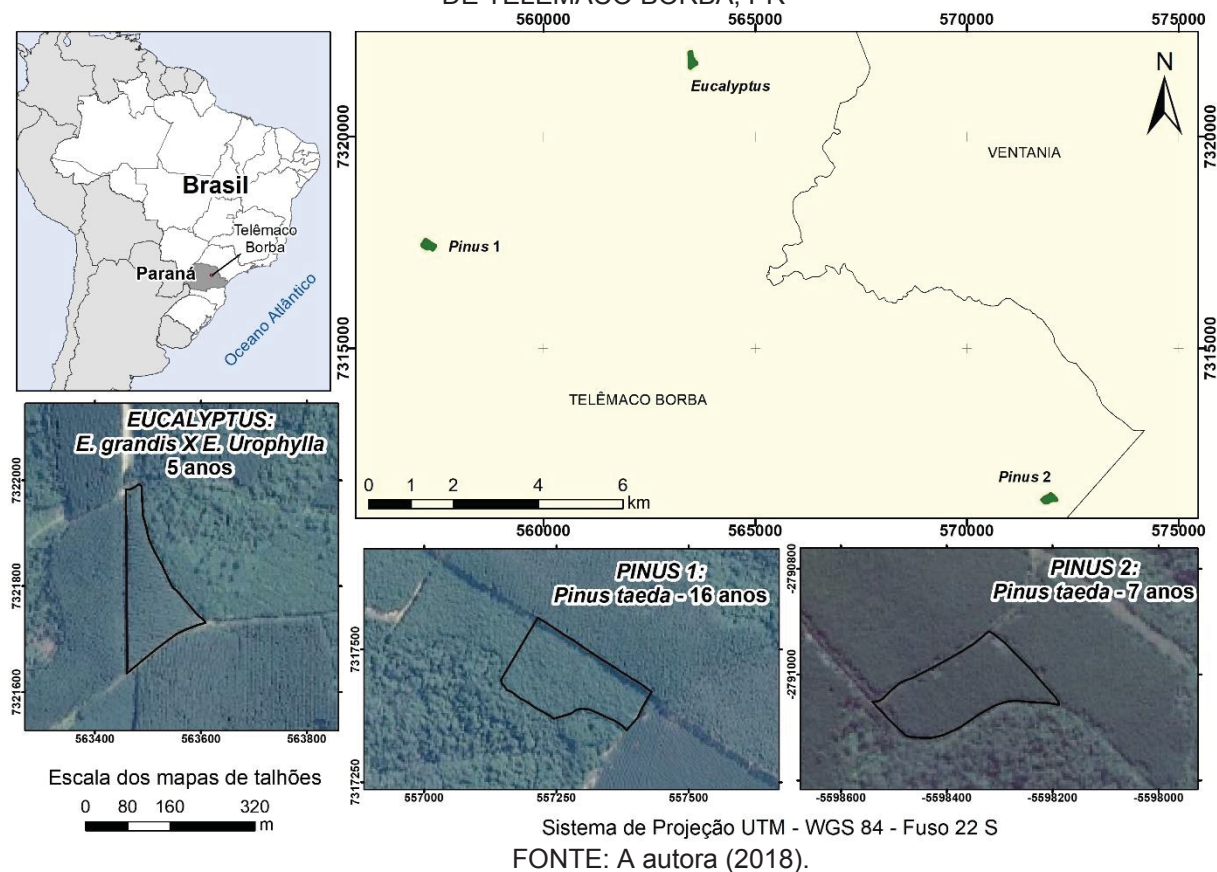
2.3.1 Área de estudo

Para este estudo foram considerados três talhões florestais pertencentes à empresa florestal Klabin S.A., localizados no município de Telêmaco Borba, estado do Paraná, Brasil. A localização da área de estudo está apresentada na FIGURA 3.

A área de estudo utilizada neste trabalho situa-se na mesorregião Centro Oriental Paranaense (IPARDES, 2012) composta por 14 municípios com uma população de aproximadamente 623.356 habitantes (IPARDES, 2004). Na mesorregião existem três microrregiões, dentre elas a microrregião de Telêmaco

Borba, composta por uma área de 9.548,508 km² e densidade demográfica de 17,88 hab.km⁻² (IPARDES, 2017a).

FIGURA 3 - LOCALIZAÇÃO DOS TALHÕES SELECIONADOS PARA O ESTUDO, NO MUNICÍPIO DE TELÊMACO BORBA, PR



Essa mesorregião é caracterizada pela presença de solos poucos férteis e declividades acentuadas, o que favorece a expansão de florestas em detrimento de lavouras (IPARDES, 2004). Mais especificamente, conforme dados do ITCG (ITCG, 2008a), na área de localização dos talhões em estudo encontram-se os solos do tipo Argissolo vermelho-amarelo distrófico típico álico (talhões *Pinus 1* e *Eucalyptus*), e Latossolo vermelho distrófico típico (talhão *Pinus 2*).

O município de Telêmaco Borba é o que mais se destaca na região, com uma área de 1.385,532 km² e população de 69.872 habitantes, com grau de urbanização de 97,95% (IPARDES, 2017b). O município encontra-se em região de ocorrência do clima Cfb (clima temperado húmido com verão temperado), com algumas regiões de transição entre Cfa (clima temperado úmido com verão quente) e Cfb, assim como pequenas áreas Af (tropical úmido) (ITCG, 2008b).

Existem duas tipologias florestais naturais predominantes na região, a Estepe gramíneo lenhosa e a Floresta Ombrófila Mista (ITCG, 2009). A Estepe gramíneo lenhosa engloba o mais abundante tipo de campos encontrado no sul do Brasil e é caracterizada pela ocorrência de extensas áreas de campo intercaladas por indivíduos arbóreos de espécies como *Araucaria angustifolia* (Bertol.) Kuntze, *Podocarpus lambertii* Klotzsch ex Endl. e *Mimosa scabrella* Benth. (BOLDRINI, 2009). Destaca-se, ainda, como característica das estepes a monotonia em termos de plantas (IBGE, 2012). Dentro da região de estepes normalmente encontram-se manchas de Floresta Ombrófila Mista dos tipos Montana (capões) e Aluvial (MAACK, 1968; MORO; CARMO, 2007). A Floresta Ombrófila Mista, por sua vez, também conhecida como Floresta com Araucária, é uma tipologia dominada por gêneros primitivos como *Drymis*, *Araucaria* e *Podocarpus* (IBGE, 2012).

2.3.2 Características dos talhões selecionados

Dos três talhões selecionados neste capítulo, dois são da espécie *Pinus taeda* L., com diferentes idades e espaçamento de plantio, e um de *Eucalyptus urograndis* (híbrido entre *E. grandis* W. Hill e *E. urophylla* S.T. Blake). As informações gerais desses talhões estão apresentadas na TABELA 8.

TABELA 8 - CARACTERÍSTICAS DOS TALHÕES SELECIONADOS EM TELÊMACO BORBA

Parâmetro	<i>Eucalyptus</i>	<i>Pinus</i> 1	<i>Pinus</i> 2
Espécie	<i>Eucalyptus urograndis</i>	<i>P. taeda</i>	<i>P. taeda</i>
Idade (anos)	5	16	7
Espaçamento (m)	3,75 x 2,4	3,0 x 2,5	2,5 x 2,5
Área total (ha)	2,30	3,08	2,81
Total de árvores esperado	2.553	4.112	4.500
Normais	1.879	291	3.706
Bifurcada abaixo do dap	112	236	168
Bifurcada acima do dap	24	538	89
Falhas	86	148	168
Mortas ou caídas	5	38	5
Quebradas	20	189	0
Dominadas	18	5	0
Fora de linha (rebrotas)	4	101	300
Torta	135	56	7
Ataque de macaco	0	2.252	2
Ataque de vespa	0	3	0
Total de árvores*	2.207	2.888	4.346


* o total de árvores não é necessariamente a soma de cada classe qualitativa, pois muitas árvores apresentaram mais de um tipo de defeito.

FONTE: A autora (2018).

O talhão de *Eucalyptus* é o menor de todos e apresenta também o maior espaçamento de plantio, de forma que compreende o menor número de árvores entre os três talhões. Em todos os talhões houve diferença entre o número de mudas calculadas pela relação entre espaçamento e área, porém essa diferença foi muito superior no talhão *Pinus* 1, no qual se esperava encontrar mais de 4 mil árvores enquanto que o real número observado foi inferior a 3 mil. Nos talhões *Eucalyptus* e *Pinus* 2 os valores encontrados foram mais próximos (entre 300 e 200 árvores).

O talhão *Pinus* 1 também se diferencia dos demais pela presença de intenso ataque do macaco-prego (*Sapajus nigritus*) nas árvores. Detalhes dos estragos causados pelo ataque de macacos podem ser visualizados na FIGURA 4.

FIGURA 4 - DETALHES DOS ESTRAGOS CAUSADOS PELOS ATAQUES DE MACACOS E VESPA DA MADEIRA NO TALHÃO *PINUS* 1



FONTE: A autora (2018).

Observou-se que no talhão *Pinus* 1 mais da metade das árvores apresentavam sinais de no mínimo um ataque, sendo que em certos casos eram observados vários pontos de ataque em uma mesma árvore. Esses ataques se dão

pela abertura de uma janela (abertura da casca em uma porção) ou pelo anelamento (abertura da casca em toda circunferência de uma porção) do tronco. Devido ao anelamento, em muitos casos, a ponta superior da árvore fica seca, devido à impossibilidade de transporte de água e nutrientes, e, em casos, ocasiona a quebra da ponta da árvore (KOEHLER; FIRKOWSKI, 1996; LIEBSCH et al., 2015). No povoamento observou-se que em muitos casos, quando a árvore estava anelada, ela desenvolveu galhos laterais em posições anteriores ao anel, que cresceram em sentido apical, assim como observado por (LIEBSCH et al., 2015). Em poucos casos também foram observados ataques da vespa da madeira (*Sirex noctilio*). O talhão de *Pinus* mais jovem não apresentou esse mesmo padrão, sendo encontradas apenas duas árvores atacadas por macaco.

2.3.3 Mensuração e caracterização dos talhões em campo

A coleta das informações dos plantios em campo foi realizada por meio do censo da população. Dessa forma, todos os indivíduos dos três talhões selecionados foram mensurados quanto à altura total e diâmetro a 1,30 m de altura (dap). A coleta foi feita nas linhas, de forma que cada árvore foi identificada pela sua linha e posição na linha. Os censos foram realizados nos mesmos meses em que foram realizados os voos, em julho de 2015 para os dois talhões de *Pinus*, e em setembro de 2015 para o talhão *Eucalyptus*.

Além da mensuração da altura total e dap, foram anotadas algumas características qualitativas das árvores conforme a relação:

- Rebrota (fora de linha);
- Bifurcada abaixo do dap;
- Falha;
- Bifurcada acima do dap;
- Abertura de janela ou anelamento por macaco;
- Atacada por vespa da madeira;
- Torta;
- Dominada;
- Quebrada;
- Morta ou caída.

A altura total foi mensurada utilizando-se de um Clinômetro Eletrônico Haglöff, no qual a altura é calculada pela relação entre distâncias e ângulos. Para a mensuração o operador deve se posicionar a uma distância de aproximadamente a altura da árvore a ser mensurada, e então posicionar a mira do clinômetro na base e posteriormente no topo da árvore alvo.

O dap foi obtido a partir do cap (circunferência a 1,30 m de altura), medida em campo por meio de fita métrica. Os dados foram armazenados em um coletor eletrônico e, posteriormente, exportados para as planilhas eletrônicas.

A partir dos dados coletados, os talhões foram analisados com base em estatísticas exploratórias (valores de média, máxima, mínima, desvios, e gráficos descritivos), de forma a verificar o perfil dos plantios. Além disso, a correlação entre os dados de altura total e dap foi avaliada pelo Coeficiente de Correlação de Pearson, utilizando o aplicativo computacional R (R CORE TEAM, 2016).

2.3.4 Sistema VANT utilizado

As fotografias aéreas foram obtidas com o VANT eBee-Ag (Sensefly) utilizando três diferentes câmeras. O VANT é composto de uma carcaça, composta principalmente de isopor, na qual podem ser acopladas variadas câmeras, conforme a necessidade. Os detalhes podem ser conferidos na FIGURA 5.

Na carcaça são observados 8 componentes principais, sendo eles: corpo principal, onde estão afixadas todas as partes; asas, que apresentam na base uma parte móvel que podem ser movimentadas para alterar direção do voo, e auxiliar na decolagem e pouso; motor e hélice, para impulsionar e movimentar o veículo aéreo; espaço para a câmera; espaço para a bateria; e sistema transmissor. Da mesma forma que a câmera pode ser removida e alternada, as asas e a hélice do motor também o podem para transporte e ser substituídas em caso de dano. O sistema conta ainda com um modem de transmissão à radio, que realiza a comunicação entre o VANT e o piloto, e de baterias que podem ser alternadas para aumentar a autonomia do voo. Na FIGURA 6 podem ser visualizados detalhes do sistema completo. Outros detalhes sobre o sistema VANT estão apresentados na TABELA 9.

FIGURA 5 - VANT UTILIZADO NO LEVANTAMENTO AÉREO



FONTE: A autora (2018).

FIGURA 6 - DETALHES DO SISTEMA VANT



FONTE: Adaptado (SENSEFLY LTD, 2014a), e arquivo pessoal.

TABELA 9 - INFORMAÇÕES ADICIONAIS SOBRE O VANT EBEE

Parâmetros	Valores
Peso	0,69 kg
Envergadura	96 cm
Tempo de voo	50 min
Velocidade	40-90 km.h ⁻¹
Alcance do rádio	Até 3km
Precisão horizontal/vertical absoluta (com GCP)	Até 3 e 5 cm
Precisão horizontal/vertical absoluta (sem GCP)	1-5 m
Precisão linear de aterrissagem	5 m

FONTE: Adaptado de SENSEFLY LTD (2014a).

Durante os voos realizados três diferentes câmeras foram utilizadas, denominadas de RGB, NIR e Multiespectral, apresentadas na FIGURA 7, com detalhes sobre as faixas do espectro eletromagnético coberto apresentados na FIGURA 8.

A câmera multiespectral, além de conter os seus 4 sensores, apresenta um sensor de irradiância solar, que juntamente com o alvo de calibração, permitem a calibração radiométrica das imagens tomadas. Na TABELA 10 estão apresentadas especificações técnicas das câmeras. É importante destacar que a distância focal não é fixa, visto que essas câmeras não são calibradas, e também não apresentam

características comuns encontradas em câmeras métricas, como por exemplo marcas fiduciais.

TABELA 10 - ESPECIFICAÇÕES DAS CÂMERAS UTILIZADAS NOS TALHÕES SELECIONADOS PARA O ESTUDO

Características	Câmera RGB	Câmera NIR	Câmera Multiespectral
Modelo	DSC-WX220	S110 NIR	Multispec 4C
Tamanho do sensor	4896 x 3672 pix	4000 x 3000 pix	1280 x 960 pix
Distância focal	4 mm	5 mm	4 mm
Resolução	350 dpi 18,8 MP	180 dpi 12 MP	96 dpi 1,2 MP
Bandas	Vermelha, Verde e Azul	Verde, Vermelha e NIR	Verde, Vermelha, Red Edge e NIR


FONTE: A autora (2018).

FIGURA 7 - CÂMERAS UTILIZADAS NOS TALHÕES SELECIONADOS PARA O ESTUDO



FONTE: A autora (2018).

FIGURA 8 - BANDAS ESPECTRAIS PRESENTES NAS CÂMERAS NIR E MULTIESPECTRAL



FONTE: Adaptado (SENSEFLY LTD, 2014b)

A banda red-edge refere-se a parte do espectro eletromagnético em que existe uma acentuação na reflectância da energia eletromagnética pela vegetação, entre 680

nm até a região em que a reflectância atinge seu máximo (ROCK et al., 1986). Essa região é particularmente importante em estudos de vegetação pois a posição e a curva de absorção têm relação direta com absorção de clorofila, sendo muito utilizada para detecção precoce de estresse na vegetação (DASH et al., 2017), classificação de estágios sucessionais (SOTHE et al., 2017), entre outros.


2.3.5 Coleta de dados VANT

Os voos foram tomados com altura que obtivesse um GSD de 5 cm para as câmeras RGB e NIR e 10 cm para a câmera multiespectral, recobrimento longitudinal e lateral de 80%, e recobrimento duplo (sobrevoo da área nos sentidos leste-oeste e norte-sul). A decisão do GSD foi tomada com base em referências encontradas na literatura e na experiência prévia dos funcionários da empresa com relação a qualidade dos ortomosaicos. O planejamento e a execução do plano de voo foram realizados com o aplicativo eMotion 2, no qual existe a opção de realizar o voo seguindo o terreno, ou seja, quando essa função é selecionada o VANT irá alterar a altitude de voo conforme a elevação da área, de forma que a altura de voo (e consequentemente, a resolução ou GSD) seja constante. A elevação do terreno é baseada em um MDS disponível no próprio *software*, sendo derivado em dados SRTM e ASTER. Na FIGURA 9 estão apresentados exemplos dos planos de voo realizados.

FIGURA 9 - EXEMPLO DE PLANOS DE VOO EXECUTADOS

Talhão *Pinus* 1

Talhão *Pinus* 2



FONTE: A autora (2018).

Os voos foram realizados em dois momentos, sendo que no primeiro (em junho de 2015) os talhões de *Pinus* foram imageados utilizando a câmera RGB. Todos os voos foram realizados entre 10 da manhã e 4 da tarde, evitando os períodos com maior ocorrência de sombra. No segundo talhão (*Pinus* 2) algumas fotografias que estavam previstas no plano de voo não foram tomadas, porque a câmera apresentou um problema mecânico, porém, apesar disso, toda a área do talhão foi recoberta com o recobrimento selecionado. Nessa mesma época os talhões foram também imageados com uma câmera da Canon com banda infravermelha (NIR).

Na segunda época (setembro de 2015) foram tomadas fotografias com uma câmera multiespectral. Nessa fase incluiu-se o talhão de *Eucalyptus*, que, portanto, foi mapeado também com a câmera NIR, porém não foi fotografado com a câmera RGB devido ao problema mecânico mencionado. Além disso, o voo com a câmera NIR do talhão de *Pinus* 1 foi realizado novamente com o objetivo de se corrigir algumas imperfeições, portanto o primeiro voo com a câmera NIR nesse talhão foi descartado. O talhão *Pinus* 2 foi mapeado com a câmera multiespectral, porém sem a utilização de pontos de controle, pois o equipamento necessário para a coleta desses não estava disponível no dia do voo. Dessa forma, foram utilizadas feições encontradas nos outros ortomosaicos para o processamento desse grupo de imagens.

Apesar de os talhões terem sido selecionados objetivando-se obter uma área aproximada de 3 ha, devido a presença de poucos locais sem copa fechada que pudessem ser utilizados para o posicionamento dos pontos de controle, em todos os casos foi sobrevoada uma área maior. No talhão *Pinus* 2 foi necessário o sobrevoos de uma área muito superior devido à presença de poucas estradas próximas ao talhão. Dessa forma, o número de imagens tomado em cada área variou significativamente. Além disso, de acordo com as características das câmeras, foram tomados diferentes números de imagens. A câmera multiespectral destacou-se por apresentar o maior número de fotografias devido ao menor formato do sensor. Além disso, para a câmera multiespectral foi necessário executar mais voos, pois essa câmera apresentou problemas de superaquecimento no dia de coleta das imagens. Na TABELA 11 está apresentado o resumo das informações coletadas durante os voos.

TABELA 11 - RESUMO DAS INFORMAÇÕES AÉREAS COLETADAS


Câmera	Parâmetro	<i>Pinus 1</i>	<i>Pinus 2</i>	<i>Eucalyptus</i>
RGB	Fotos (n°)	204	554	-
	Data (d/m/a)	29/06/2015	29/06/2015	-
	Voos (n°)	1	2	-
	Área coberta (ha)	33,3	156,9	-
	Tempo de voo (h:m:s)	00:18:00	00:54:00	-
NIR	Fotos (n°)	265	648	193
	Data (d/m/a)	17/09/2015	30/06/2015	17/09/2015
	Voos (n°)	2	3	2
	Área coberta (ha)	52,0	126,1	39,99
	Tempo de voo (h:m:s)	00:37:00	1:14:00	00:31:00
Multiespectral	Fotos (n°)	913	1291	488
	Data (d/m/a)	17/09/2015	18/09/2015	17/09/2015
	Voos (n°)	6	10	3
	Área coberta (ha)	59,2	90,8	49,2
	Tempo de voo (h:m:s)	01:58:00	04:37:00	01:10:00

FONTE: A autora (2018).

Durante a realização dos voos com a câmera multiespectral foi também utilizado o alvo de calibração radiométrica, conforme FIGURA 10. Para a calibração das imagens é necessária a tomada de ao menos uma fotografia do alvo com o VANT a uma distância de 0,5-1 m do alvo. O alvo deve estar posicionado em nível e em pleno sol (sem sombras em nenhuma parte do alvo). Esse procedimento foi realizado antes de cada voo assegurar que as condições de luminosidade na hora da tomada da imagem do alvo eram as mesmas do restante das fotografias. A calibração foi somente realizada para a câmera multiespectral, pois é a única que apresentava o alvo de calibração com reflectâncias conhecidas para as bandas individualizadas.

FIGURA 10 - CALIBRAÇÃO RADIOMÉTRICA DA CÂMERA MULTIESPECTRAL

Método para tomada de fotografia para calibração



Procedimento executado em campo




FONTE: Adaptado de (SENSEFLY LTD, 2014c) e arquivo pessoal.

2.3.6 Coleta dos pontos de controle

No momento da realização dos voos foram também alocados alvos no chão para servirem de pontos de controle. Esses foram utilizados no processamento das imagens. Os alvos foram confeccionados com papel branco em formato quadrado com aproximadamente 1,8 m de lado. O centro do papel foi demarcado com *spray* preto. Foram alocados 4 pontos de controle em cada talhão, posicionados nos cantos mais externos de cada talhão.

A coordenada do centro de cada ponto de controle foi coletada com um GPS Pathfinder ProXRT Receiver de precisão da Trimble, conforme detalhe na FIGURA 11. Nos casos em que foram realizados voos em dias distintos, em um mesmo talhão, foi necessário fazer o posicionamento e coleta de coordenadas em cada data, pois o material utilizado não permitia que os alvos fossem posicionados permanentemente.

FIGURA 11 - COLETA E DEMARCAÇÃO DOS PONTOS DE CONTROLE
Coleta das coordenadas dos pontos de controle Ponto de controle demarcado nas fotografias aéreas



FONTE: A autora (2018).

Após a coleta em campo, os dados coletados com o GPS foram importados no *software* GPS Pathfinder Office, a partir do qual foi possível obter as coordenadas e precisão de cada ponto, conforme TABELA 12. O voo realizado no talhão *Pinus 2* com a câmera Multiespectral foi o único em que não se utilizou pontos de controle, devido à indisponibilidade de GPS no dia da coleta. Infelizmente, a precisão dos pontos de controle coletados em junho de 2015 no talhão *Pinus 1* RGB foi abaixo da esperada, portanto o sobrevoo com a câmera NIR foi realizado novamente.

TABELA 12 - COORDENADAS E PRECISÕES DOS PONTOS DE CONTROLE

Talhão	Câmeras	Pto.	Coordenadas (m)			Precisão (m)	
			X	Y	Z	Vert.	Hor.
<i>Eucalyptus</i>	NIR Multispec	1	563.486,706	7.321.997,212	955,664	0,4	0,2
		2	563.460,172	7.321.981,545	957,652	0,6	0,4
		3	563.464,391	7.321.641,481	976,227	0,5	0,3
		4	563.613,611	7.321.729,637	964,958	0,4	0,2
<i>Pinus 1</i>	RGB	1	557.450,658	7.317.396,749	950,365	4,1	2,0
		2	557.338,333	7.317.172,869	938,527	1,3	1,0
		3	556.955,930	7.317.565,366	921,149	4,7	2,3
		4	557.033,639	7.317.677,349	927,603	1,8	0,7
<i>Pinus 1</i>	NIR Multispec	1	557.451,272	7.317.405,775	954,444	1,2	0,5
		2	557.319,910	7.317.191,269	937,174	0,9	0,6
		3	556.954,914	7.317.557,561	926,005	0,6	0,3
		4	557.035,795	7.317.677,824	936,021	0,8	0,4
<i>Pinus 2</i>	RGB NIR	1	571.472,732	7.311.795,607	966,296	1,0	0,5
		2	571.758,946	7.311.954,683	964,427	1,0	0,6
		3	572.612,383	7.310.978,678	911,392	1,1	0,6
		4	572.666,404	7.311.079,062	914,341	1,1	0,6

FONTE: A autora (2018).

2.3.7 Processamento das imagens

Após a tomada das imagens foi realizada a inclusão das coordenadas x, y e z do VANT no momento de coleta de cada imagem. Essas coordenadas são originalmente armazenadas no registro de voo e posteriormente são incluídas no próprio arquivo da imagem. Esse processo, conhecido como *Geotag* (inclusão de coordenadas em um arquivo digital), é realizado no próprio *software* de planejamento de voo, o eMotion.

Dada a capacidade de calibração radiométrica das imagens multiespectrais, e a semelhança entre o resultado dos *softwares* mais utilizados para o processamento de imagens, neste trabalho as imagens foram processadas com o Pix4Dmapper (versão 3.2.17), para a geração dos respectivos ortomosaicos, MDS (Modelo Digital de Superfície) e nuvem de pontos densificada. O processamento nesse *software* é baseado em três principais etapas: 1) processamento inicial (*initial processing*); 2) nuvem de pontos e malha 3D (*point cloud and mesh*); 3) MDS, ortomosaico e índice (*DSM, orthomosaic and index*).

Durante o processamento inicial definiu-se a escala de detecção dos pontos-chave (*keypoints*) como completa, o tipo de coleta de dados como aéreo, o ajustamento e a calibração como clássicos e sem limite de pontos-chave, e a otimização de todos os parâmetros de orientação interior e exterior. Na etapa de densificação os seguintes parâmetros foram selecionados: densidade de pontos alta,

½ da escala das imagens (escala variável), ponto visível em pelo menos 3 imagens, e exportação da nuvem em formato “las”. A malha 3D não foi gerada nessa etapa, pois não seria utilizada. Na última etapa foram selecionados os seguintes parâmetros: resolução do MDS e ortomosaico automática (1 GSD), filtragem de ruídos na geração do MDS e interpolação pelo método de Ponderação pelo Inverso da Distância (IDW). Esse procedimento foi realizado para as câmeras RGB e NIR.

Para a câmera multiespectral foram realizadas poucas alterações de forma a melhor adequar o processamento. Como essa câmera é composta por 4 sensores individualizados, o processamento é realizado para cada sensor, portanto o tempo de processamento é maior. Dessa forma, algumas opções para acelerar o processamento foram selecionadas e observou-se que os resultados foram adequados. No caso da câmera multiespectral, portanto a escala de detecção dos pontos-chaves rápida foi selecionada e a densidade de pontos como ótima. Os demais parâmetros foram mantidos os mesmos. Além disso, os sensores dessa câmera foram calibrados a partir das informações de albedo do alvo de calibração. O *software* apresenta três opções de correção e, nesse caso, foi aplicada a correção da câmera e da irradiância do sol. Para tanto, a fotografia do alvo tomada antes do voo (para os 4 sensores) foi importada, a área da fotografia que continha a amostra de valores conhecidos foi selecionada e os valores de albedo (Verde = 19,2%, Vermelha = 19,8%, NIR = 26,6% e Red Edge = 32,5%) foram inseridos. A partir dessa correção foram obtidos os mapas de refletância para cada sensor, assim como os demais produtos, como MDS e nuvem de pontos.

2.3.8 Dados LiDAR

Além da coleta de imagens por VANT, neste trabalho também se utilizou de dados de um levantamento com LiDAR realizado em 2017 por uma empresa especializada em mapeamentos aéreos e contratada pela Klabin SA. Um outro voo LiDAR realizado em 2012 também estava disponível, porém optou-se por somente utilizar-se os dados LiDAR de 2017 porque essa coleta apresentou melhor alinhamento com os dados VANT. A coleta foi realizada utilizando um sensor LiDAR Harrier 68i da Trimble, embarcado numa aeronave CESSNA 206, e com sistema de navegação (IMU+GPS) Appalanix POS AV 150. Os parâmetros da coleta foram: 5 pontos por m²; intensidade de 1:2000 (50 cm); resolução de 50 cm; exatidão de 50

cm; altura do voo de 666,14 m; ângulo de visada (FOV) de 60°; e sobreposição lateral de 30%. Os dados foram fornecidos em formato “*las*”, no sistema de coordenadas UTM SIRGAS 2000.

A nuvem LiDAR de cada talhão foi processada separadamente, sendo, portanto, primeiramente realizado o recorte da mesma (em área que cobrisse o talhão e uma margem de erro), utilizando-se da ferramenta *Polyclipdata* do *software* para processamento de dados Fusion versão 3.70 (MCGAUGHEY, 2018). Após o recorte, a nuvem passou pelo processo de classificação dos pontos relativos ao solo, utilizando o *software* RSC LAS Tools (ARMSTON, 2012), que realiza a classificação dos pontos no solo baseado no Filtro Morfológico Progressivo desenvolvido por Zhang et al. (2003). Para a classificação, os parâmetros de execução do filtro foram definidos como: 1 m de raio de busca inicial; 7 m de raio máximo de busca; 0,5 m como limite de diferença da altura inicial; 30% de declividade; 1 m de espaçamento da grade de pontos; e 0,15 m de tolerância de erro.

Em análise feita sobre as nuvens do VANT e os dados do LiDAR, observou-se que existia um deslocamento vertical entre os dois, portanto foi necessário realizar o alinhamento das nuvens antes da geração do MDT (Modelo Digital do Terreno). Para o alinhamento da nuvem do LiDAR utilizou-se o *software* CloudCompare versão Omnia 2.9.1. O processo de alinhamento foi realizado utilizando-se a nuvem de pontos gerada com a nuvem do VANT com sensor NIR de cada talhão como controle, sendo essa escolha justificada devido ter sido realizado sobrevoos com essa câmera e com adequados pontos de controle para os três talhões. Além do alinhamento dos dados do LiDAR, as nuvens do VANT das diversas câmeras foram também analisadas e observou-se discrepâncias entre a nuvem do VANT com sensor RGB e as demais nuvens no talhão *Pinus* 1, lembrando-se que o voo RGB desse talhão foi efetuado em uma data distinta e com pontos de controle com qualidade inferior. Dessa forma, a nuvem do sensor RGB do talhão *Pinus* 1 também foi alinhada em relação a nuvem do sensor NIR.

Existem diversos métodos de alinhamento no CloudCompare e, nesse caso, foi utilizado o método de seleção de pontos equivalentes. Portanto, pelo menos 4 pontos devem ser selecionados em ambas as nuvens (nuvem de referência e nuvem a ser alinhada) e, a partir desses pontos, é gerada uma matriz de transformação 4x4. Nesse caso foram utilizados pontos marcados na área em que se encontravam os pontos de controle utilizados no processamento das imagens, apesar de eles não

serem visíveis no LiDAR. Dessa forma, pontos nas duas nuvens foram selecionados e, considerando-se que as duas nuvens estavam horizontalmente alinhadas (verificado de forma visual), pontos correspondentes próximos foram identificados, cuidando-se para selecioná-los quando identificados como solo no caso da nuvem do LiDAR. A escala foi mantida sem alteração, pois o único deslocamento observado nas nuvens era o posicionamento em Z.

No caso da nuvem do LiDAR do talhão *Pinus 2*, não foi possível utilizar as posições dos pontos de controle, porque a localização de dois desses pontos não estava representada na nuvem do LiDAR, visto que foram posicionados fora da área de propriedade da empresa que cedeu os dados. Para fazer o alinhamento desse caso foram então selecionados 5 pontos, que se encontravam visivelmente em solo. O resumo das nuvens alinhadas está apresentado na TABELA 13, e as matrizes de transformação utilizadas estão apresentadas na FIGURA 12.

TABELA 13 - PROCESSO DE ALINHAMENTO DAS NUUVENS DE PONTOS

Talhão	Nuvem alinhada	Referência	Pontos (nº, tipo)	RMSE
<i>Eucalyptus</i>	LiDAR 2017	Nuvem NIR	4, controle	0,270636
<i>Pinus 1</i>	LiDAR 2017	Nuvem NIR	4, controle	0,168524
<i>Pinus 1</i>	Nuvem RGB	Nuvem NIR	4, controle	0,291946
<i>Pinus 2</i>	LiDAR 2017	Nuvem NIR	5, selecionados	0,439802

FONTE: A autora (2018).

FIGURA 12 - MATRIZES DE TRANSFORMAÇÃO UTILIZADAS NO ALINHAMENTO DAS NUUVENS DE PONTOS

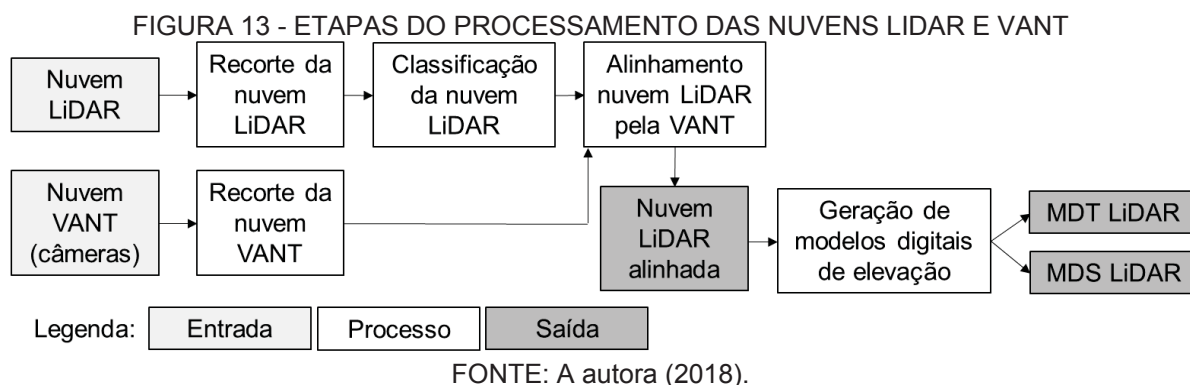
<i>Eucalyptus</i> – nuvem LiDAR				<i>Pinus 1</i> – nuvem LiDAR			
1.000	-0.000	-0.001	0.036	1.000	-0.000	0.005	-0.095
0.000	1.000	-0.011	0.456	0.001	1.000	-0.019	0.801
0.001	0.011	1.000	1.815	-0.005	0.019	1.000	3.363
0.000	0.000	0.000	1.000	0.000	0.000	0.000	1.000
<i>Pinus 2</i> – nuvem LiDAR				<i>Pinus 1</i> – nuvem RGB			
1.000	-0.000	0.001	-0.241	1.000	-0.001	-0.001	0.412
0.000	1.000	0.001	-0.291	0.001	1.000	-0.018	0.070
-0.001	-0.001	1.000	3.453	0.001	0.018	1.000	-1.474
0.000	0.000	0.000	1.000	0.000	0.000	0.000	1.000

Fonte: A autora (2018).

Após o alinhamento, as nuvens foram conferidas pela seleção de áreas em solo aberto, como estradas e aceiros, de tal maneira a se confirmar que os estavam compatíveis. Além das nuvens alinhadas, todas as nuvens VANT foram confrontadas com a nuvem NIR para se verificar anomalias, porém o único problema encontrado foi em relação à nuvem RGB do *Pinus 1*, que foi, portanto, realinhada.

Na última etapa do processamento dos dados LiDAR de cada talhão foram gerados os modelos de elevação (MDT, MDS), a partir de cada nuvem do LiDAR alinhada. Essa etapa foi realizada utilizando o *software* Fusion (MCGAUGHEY, 2018). O MDT foi gerado utilizando a ferramenta *GridSurfaceCreate* a partir dos pontos classificados como solo. Já o MDS foi gerado com a ferramenta *Canopymodel*. Os modelos MDT e MDS a partir da nuvem do LiDAR foram gerados com resolução de 0,5 m.

O resumo do processo de alinhamento e obtenção dos modelos de superfície pelos dados do LiDAR estão apresentados na FIGURA 13. Devido à necessidade de alinhamento da nuvem VANT da câmera RGB no talhão *Pinus 1*, foi também gerado um novo MDS a partir dessa nuvem após o alinhamento e, nesse caso, o processo foi realizado também com o *software* Fusion, com a diferença que a resolução foi definida como 5 cm, de acordo com a resolução que originalmente foi obtida no processamento das imagens.



2.3.9 Análise da qualidade

A análise da qualidade dos produtos obtidos por meio processamento das imagens obtidas pelo VANT foi realizada pelos valores de RMSE. Infelizmente, devido às características da área, com poucos espaços abertos, não foi possível a inclusão de pontos de verificação, portanto o RMSE calculado se refere aos próprios pontos de controle.

Além do RMSE, o posicionamento dos pontos de controle nos ortomosaicos finais foi avaliado de forma visual, considerando-se o posicionamento em X e Y. Para avaliar o posicionamento em altitude, a coordenada Z de cada ponto de controle foi

comparada com o valor de Z em cada MDT gerado e ainda comparado com o mesmo valor gerado pelo sobrevoo com o LiDAR.

Para a apresentação dos mapas com elevações, optou-se por recortar a área dos talhões, de forma a apresentar apenas as variações existentes na área de interesse. Portanto, realizou-se o recorte dos modelos considerando-se o limite do talhão com uma margem extra de 10 metros.

2.4 RESULTADOS

2.4.1 Dados proveniente do VANT

2.4.1.1 Talhão *Eucalyptus*

Para o talhão *Eucalyptus* foram gerados um ortomosaico (pela câmera NIR) e 4 mapas de reflectância (pela câmera Multispectral). Devido ao defeito mecânico na câmera RGB, não foi possível o imageamento desse talhão nas cores RGB. O ortomosaico bem como as composições obtidas pelos mapas de reflectância da câmera multispectral estão apresentados nas FIGURA 14 e 15. As estatísticas gerais dos dois processamentos estão apresentadas na TABELA 14.

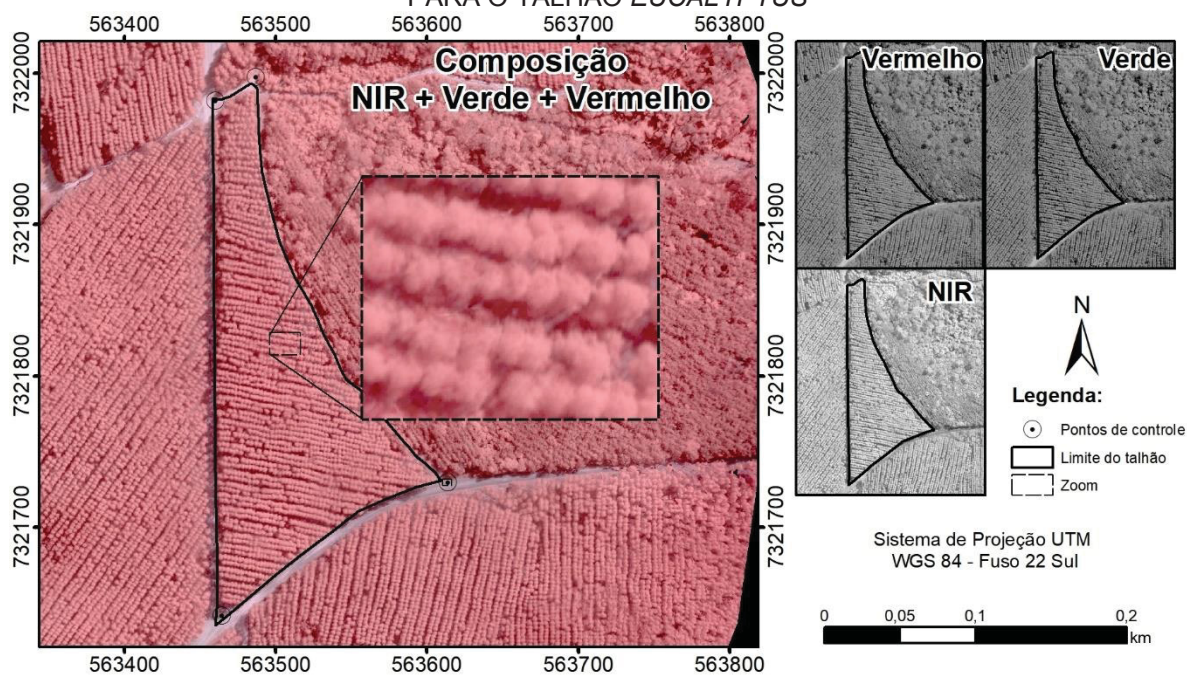
TABELA 14 - ESTATÍSTICAS GERAIS DOS PROCESSAMENTOS DO TALHÃO *EUCALYPTUS*

Etapas	Parâmetros	NIR	Multispectral
Inicial (alinhamento)	RMSE	0,073 m	0,074 m
	Tempo	23m:38s	49m:21s
	Imagens alinhadas	190 de 191 (99%)	1880 de 1952 (96%)
Densificação da nuvem	Tempo para densificar	01h:53m:41s	36m:41s
	Total de pontos 3D	38.394.591	9.195.400
	Densidade de pontos (m ³)	14,45	1,34
MDS e ortomosaico	Resolução (cm.pixel ⁻¹)	6,19	13,29
	Tempo para gerar MDS	01h:20m:30s	26m:30s
	Tempo ortomosaico*	23m:48s	31m:29s

* soma do tempo para cada mapa de reflectância no caso da câmera multispectral.

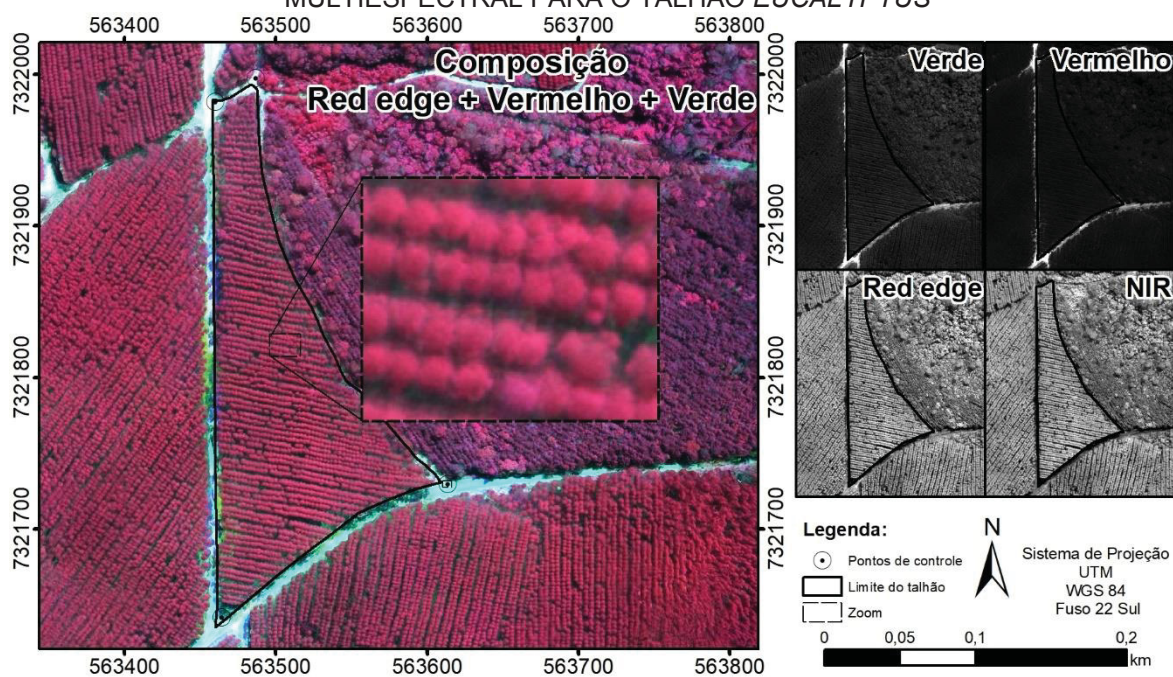
FONTE: A autora (2018).

FIGURA 14 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA NIR PARA O TALHÃO *EUCALYPTUS*



FONTE: A autora (2018).

FIGURA 15 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA MULTIESPECTRAL PARA O TALHÃO *EUCALYPTUS*



FONTE: A autora (2018).

A precisão do ajustamento dos dois ortomosaicos, dada pelos pontos de controle, está apresentada na TABELA 15.

TABELA 15 - ERROS DO AJUSTAMENTO DAS CÂMERAS NIR E MULTIESPECTRAL, DADOS PELOS PONTOS DE CONTROLE, PARA O TALHÃO *EUCALYPTUS*

Pontos	Imagens	Câmera NIR			Imagens	Câmera Multiespectral		
		X	Y	Z		X	Y	Z
1	32	-0,013	-0,071	0,177	169	-0,033	-0,059	0,229
2	33	0,022	0,052	-0,216	167	0,032	0,055	-0,211
3	26	-0,036	0,009	0,047	98	-0,009	0,002	0,007
4	33	0,048	0,006	-0,051	109	0,020	0,004	-0,037
Média (m)	-	0,005	-0,001	-0,011	-	0,002	0,001	-0,003
RMSE (m)	-	0,033	0,044	0,144	-	0,026	0,040	0,157

FONTE: A autora (2018)

Além dos ortomosaicos, também foi obtido um MDS a partir de cada câmera, apresentados na FIGURA 16. Nos detalhes das figuras também estão apresentados os MDT e MDS obtidos pelo LiDAR. Os parâmetros das nuvens de pontos, LiDAR e derivadas de VANT, que deram origem aos MDEs (Modelo Digital de Elevação), estão apresentadas na TABELA 16.

TABELA 16 - RESUMO DAS NUUVENS DE PONTO VANT E LIDAR UTILIZADAS PARA O TALHÃO *EUCALYPTUS*

Sensor	Banda	Total de pontos	Densidade (ptos/m ²)
VANT, câmera NIR	-	16.372.262	150,88
	Verde	1.089.534	10,04
VANT, câmera multiespectral	NIR	1.242.555	11,45
	Red Edge	1.230.302	11,34
	Vermelho	733.567	6,76
LiDAR	-	979.231	9,00

FONTE: A autora (2018)

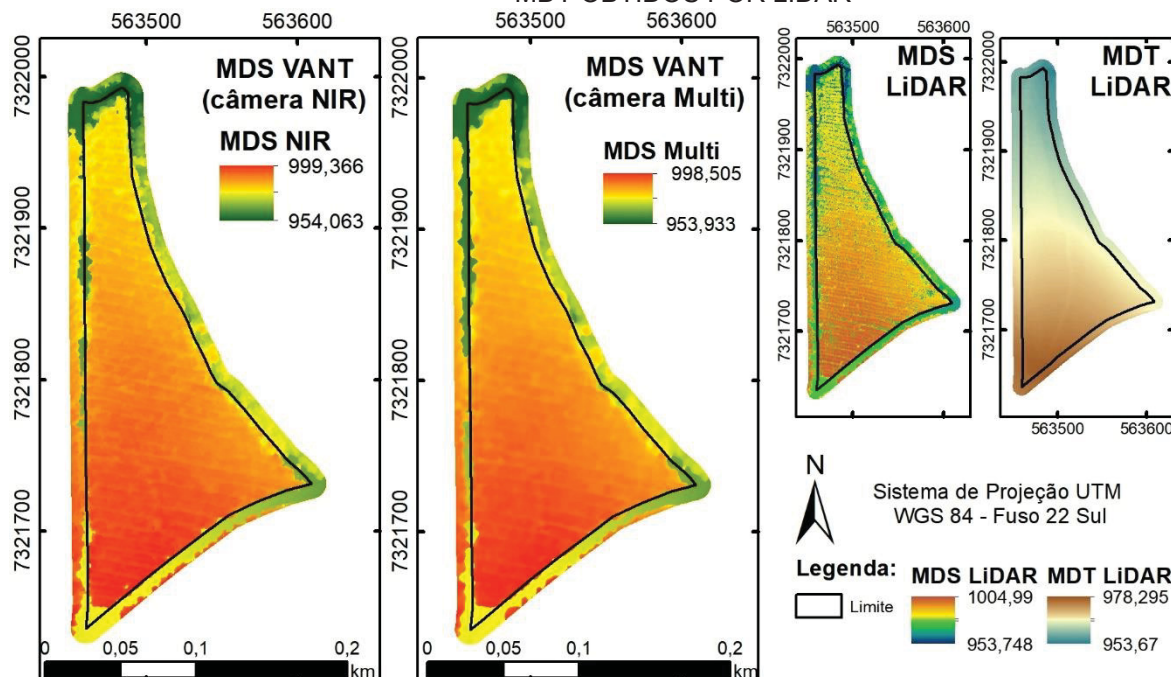
Na FIGURA 17 estão apresentados os posicionamentos de cada ponto de controle no ortomosaicos. A precisão vertical também foi avaliada pelo valor de Z em cada ponto de controle, assim como para os produtos modelos de superfície obtidos pelo LiDAR, conforme TABELA 17.

TABELA 17 - COMPARAÇÃO ENTRE OS VALORES Z OBTIDOS PARA CADA PONTO DE CONTROLE NOS MDE OBTIDOS POR LIDAR E VANT, PARA OS VOOS REALIZADOS NO TALHÃO *EUCALYPTUS*

Ponto	GPS	MDS VANT NIR		MDS VANT Multi.		MDS LiDAR alinhado		MDT LiDAR alinhado	
		Z	Erro (m)	Z	Erro (m)	Z	Erro (m)	Z	Erro (m)
1	955,66	955,56	0,10	955,49	0,17	955,33	0,34	955,31	0,36
2	957,65	958,03	-0,38	957,96	-0,31	958,31	-0,66	958,30	-0,65
3	976,23	976,39	-0,16	976,26	-0,03	976,20	0,03	976,20	0,03
4	964,96	965,18	-0,22	965,00	-0,04	965,47	-0,51	965,47	-0,51
Média	-	-	-0,16	-	-0,05	-	-0,20	-	-0,19


FONTE: A autora (2018).

FIGURA 16 - MDE GERADOS COM AS FOTOGRAFIAS TOMADAS COM AS CÂMERAS NIR E MULTIESPECTRAL PARA O TALHÃO *EUCALYPTUS*, COM DETALHES DOS MDS E MDT OBTIDOS POR LIDAR



FONTE: A autora (2018).

FIGURA 17 - ANÁLISE VISUAL DA QUALIDADE DO POSICIONAMENTO DOS ORTOMOSAICOS NOS PONTOS DE CONTROLE, PARA O TALHÃO *EUCALYPTUS*



FONTE: A autora (2018).

2.4.1.2 Talhão *Pinus* 1

O talhão de *Pinus* com 16 anos de idade (*Pinus* 1), teve seu recobrimento feito com as três câmeras. Apesar de o levantamento ter sido realizado em épocas diferentes, poucas alterações são observadas na área, com exceção da colheita de parte de um talhão vizinho de *Eucalyptus*, que é visível apenas no imageamento RGB

(realizado em junho). Os resultados do mapeamento estão apresentados nas FIGURA 18, 19 e 20, para os ortomosaicos e mapas de reflectância.

As estatísticas do ajustamento estão apresentadas na TABELA 18, e a precisão do ajustamento dos três ortomosaicos, dada pelos pontos de controle, está apresentada na TABELA 19.

TABELA 18 - ESTATÍSTICAS DO AJUSTAMENTO DAS FOTOGRAFIAS AÉREAS COLETADAS PARA O TALHÃO *PINUS* 1, COM AS CÂMERAS RGB, NIR E MULTIESPECTRAL

Etapas	Parâmetros	RGB	NIR	Multiespectral
Inicial (alinhamento)	RMSE	0,034 m	0,052 m	0,105 m
	Tempo	01h:06m:55s	01h:03m:30s	7h:35m:01s
	Imagens alinhadas	189 de 204 (92%)	261 de 265 (98%)	3528 de 3668 (96%)
Densificação da nuvem	Tempo Densificação	02h:40m:31s	02h:32m:53s	1h:25m:21s
	Total de pontos 3D	55.643.700	60.545.261	20.096.214
	Densidade de pontos (m ³)	47,5	28,57	2,25
MDS e ortomosaico	Resolução (cm.pixel ⁻¹)	5,02	5,33	11,72
	Tempo para gerar MDS	01h:53m:53s	02h:03m:32s	01h:16m:50s
	Tempo ortomosaico*	31m:43s	39m:19s	01h:58m:26s

* soma do tempo para cada mapa de reflectância no caso da câmera multispectral.

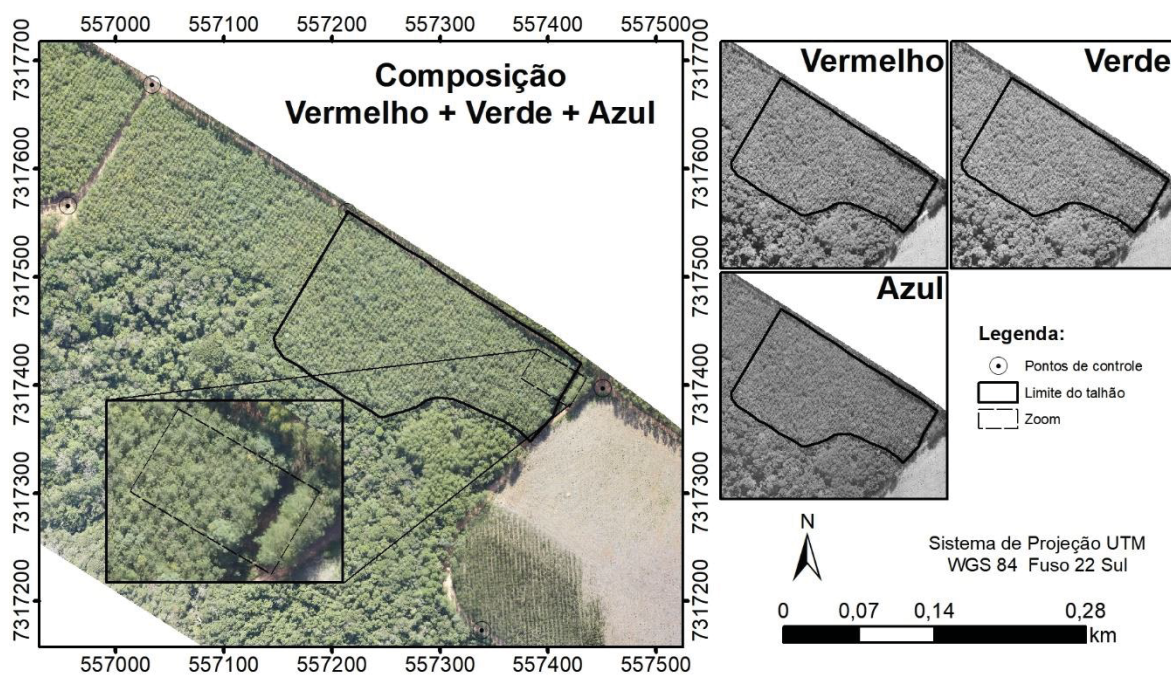
FONTE: A autora (2018).

TABELA 19 - ERROS DO AJUSTAMENTO DAS CÂMERAS RGB, NIR E MULTIESPECTRAL, DADOS PELOS PONTOS DE CONTROLE, PARA O TALHÃO *PINUS* 1

Pontos	Câmera RGB				Câmera NIR				Câmera Multiespectral			
	N	X	Y	Z	N	X	Y	Z	N	X	Y	Z
1	15	-0,02	0,06	0,05	25	0,07	0,02	0,00	83	0,09	0,03	-0,02
2	39	0,01	-0,07	-0,01	19	-0,07	0,05	-0,03	120	-0,09	0,09	-0,09
3	27	-0,02	0,09	0,00	27	-0,12	-0,05	-0,01	189	-0,24	-0,10	0,00
4	21	0,02	-0,04	0,00	19	0,15	-0,01	-0,01	118	0,25	-0,01	0,08
Média (m)	-	0,00	0,01	0,01	-	0,00	0,00	-0,01	-	0,00	0,00	-0,01
RMSE (m)	-	0,02	0,07	0,02	-	0,11	0,04	0,02	-	0,18	0,07	0,06


FONTE: A autora (2018).

FIGURA 18 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA RGB PARA O TALHÃO PINUS 1



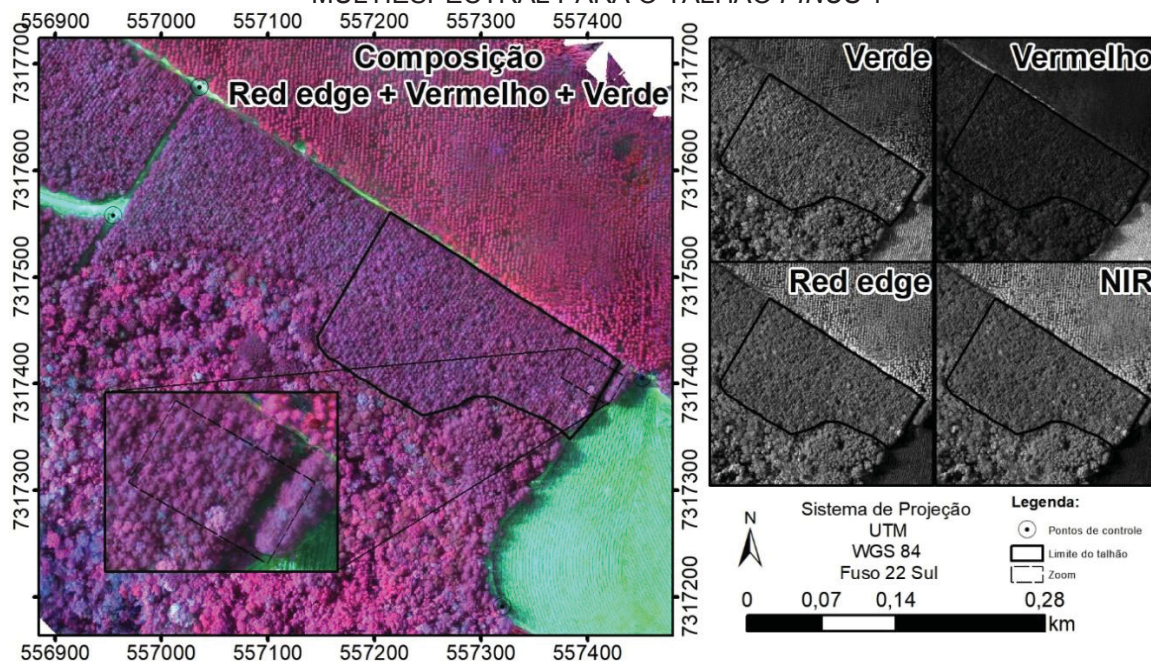
FONTE: A autora (2018).

FIGURA 19 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA NIR PARA O TALHÃO PINUS 1



FONTE: A autora (2018).

FIGURA 20 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA MULTIESPECTRAL PARA O TALHÃO PINUS 1



FONTE: A autora (2018).

Na FIGURA 21 estão apresentados os MDS obtidos com as três câmeras, assim como o MDT e MDS obtido pelo LiDAR. No caso do MDS derivado da câmera RGB, vale ressaltar que a nuvem de pontos foi realinhada em relação à nuvem NIR, e que o MDS foi gerado com o Fusion após o alinhamento. Os parâmetros das nuvens utilizadas para a geração dos MDS e MDT estão apresentados na TABELA 20.

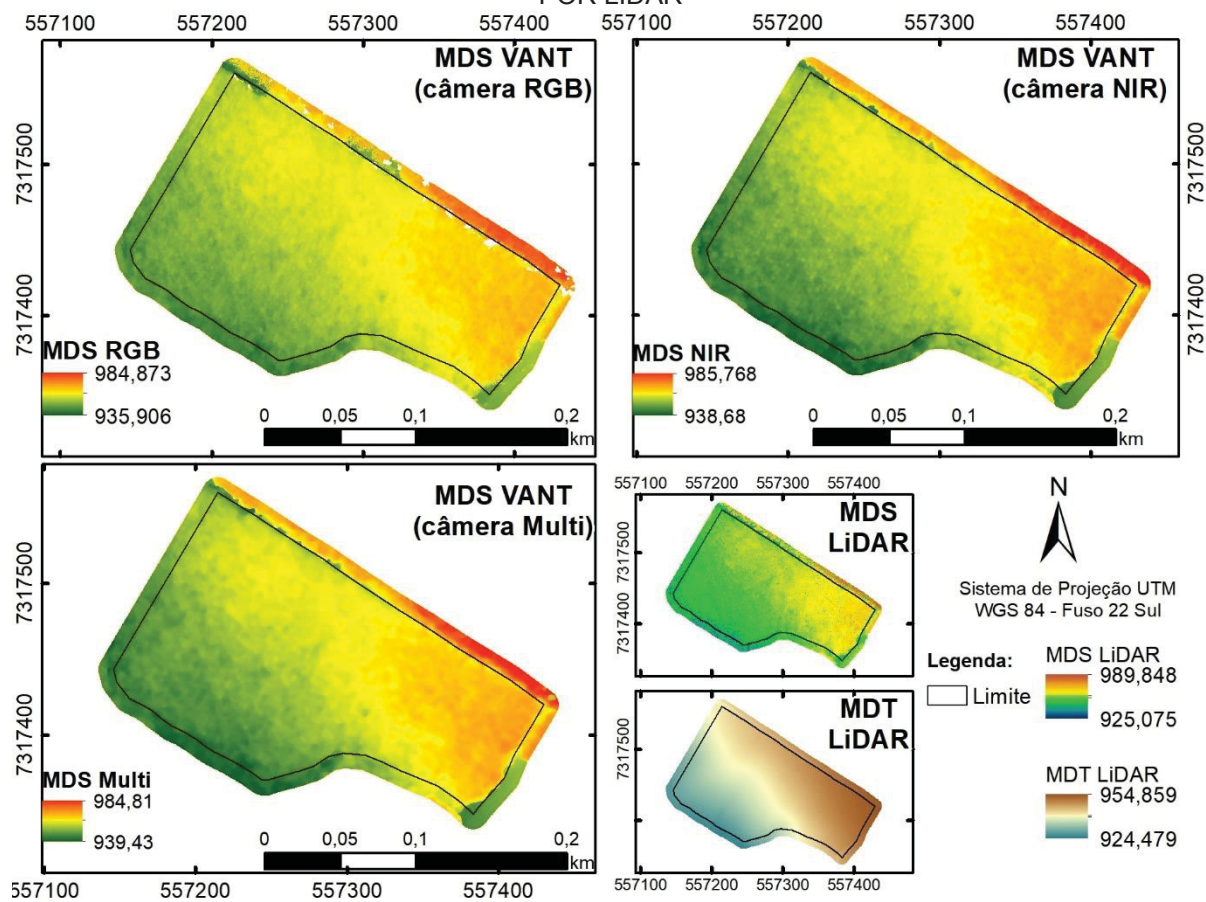
Na FIGURA 22 estão apresentados os posicionamentos de cada ponto de controle nos ortomosaicos e mapas de reflectância. Quanto ao posicionamento dos pontos de controle na coordenada Z dos modelos de elevação, estes estão apresentados na TABELA 21 para o levantamento RGB realizado em junho. Como a nuvem de pontos RGB foi alinhada em relação a nuvem NIR, a comparação foi realizada em relação ao MDS NIR, porém na posição dos pontos de controle.

TABELA 20 - RESUMO DAS NUVENS VANT E LIDAR UTILIZADAS PARA O TALHÃO PINUS 1

Sensor	Banda	Total de pontos	Densidade (m ²)
VANT, câmera RGB	-	40.039.235	98,56
VANT, câmera NIR	-	35.436.077	85,55
VANT, câmera Multiespectral	Verde	2.906.929	7,02
	NIR	2.874.111	6,94
	Red Edge	2.901.907	7,02
	Vermelho	2.713.978	6,66
LiDAR	-	1.928.843	4,65


Fonte: A autora (2018).

FIGURA 21 - MDS GERADOS COM AS FOTOGRAFIAS TOMADAS COM AS CÂMERAS RGB, NIR E MULTIESPECTRAL PARA O TALHÃO *PINUS* 1 COM DETALHES DOS MDS E MDT OBTIDOS POR LIDAR



FONTE: A autora (2018).

FIGURA 22 - ANÁLISE VISUAL DA QUALIDADE DO POSICIONAMENTO DOS ORTOMOSAICOS EM RELAÇÃO AOS PONTOS DE CONTROLE PARA O TALHÃO *PINUS* 1



FONTE: A autora (2018).

TABELA 21 - COMPARAÇÃO ENTRE OS VALORES Z OBTIDOS NOS MDE LIDAR E VANT EM RELAÇÃO AO MDS NIR (REFERÊNCIA), PARA OS VOOS REALIZADOS EM JUNHO NO TALHÃO *PINUS 1*

Ponto	MDS VANT NIR		MDS VANT RGB		MDS LiDAR alinhado		MDT LiDAR alinhado	
	Z		Z	Erro (m)	Z	Erro (m)	Z	Erro (m)
1	954,63		954,78	-0,15	954,45	0,18	954,39	0,24
2	938,27		938,61	-0,34	950,28	-12,01	938,23	0,04
3	927,91		927,96	-0,05	927,59	0,32	927,56	0,35
4	936,25		936,28	-0,03	936,20	0,05	936,20	0,05
Média	-		-	-0,14	-	-2,86	-	0,17

FONTE: A autora (2018).

Na TABELA 22 estão apresentados os dados para o levantamento com as câmeras NIR e multiespectral realizado em setembro.

TABELA 22 - COMPARAÇÃO ENTRE OS VALORES Z OBTIDOS PARA CADA PONTO DE CONTROLE NOS MDE OBTIDOS POR LIDAR E VANT, PARA OS VOOS REALIZADOS EM SETEMBRO NO TALHÃO *PINUS 1*

Ponto	GPS	MDS VANT NIR		MDS VANT Multi.		MDS LiDAR alinhado		MDT LiDAR alinhado	
		Z	Erro (m)	Z	Erro (m)	Z	Erro (m)	Z	Erro (m)
1	954,44	954,58	-0,14	954,56	-0,11	954,50	-0,06	954,50	-0,06
2	937,17	937,49	-0,32	937,38	-0,21	937,66	-0,48	937,47	-0,29
3	926,01	926,11	-0,10	926,03	-0,03	926,06	-0,06	926,04	-0,03
4	936,02	936,26	-0,24	935,95	0,07	936,12	-0,09	936,12	-0,09
Média	-	-	-0,20	-	-0,07	-	-0,17	-	-0,12

FONTE: A autora (2018).

2.4.1.3 Talhão *Pinus 2*

Para o talhão de *Pinus* com 7 anos (*Pinus 2*), também foi possível realizar o levantamento com as três câmeras selecionadas. Para o levantamento da câmera Multiespectral não puderam ser coletados pontos de controle com o GPS, portanto o ajustamento foi realizado com base em pontos observados no ortomosaico gerado com a câmera RGB. Os ortomosaicos e mapas de reflectância gerados estão apresentados nas FIGURAS 23 até 25.

As estatísticas dos processamentos estão apresentadas TABELA 23, enquanto que na FIGURA 26 estão os MDS gerados pelo levantamento VANT com as três câmeras, assim como detalhes do MDT e MDS gerado pelo LiDAR.


TABELA 23 - ESTATÍSTICAS DO PROCESSAMENTO COM AS CÂMERAS RGB, NIR E MULTIESPECTRAL PARA O TALHÃO PINUS 2

Etapas	Parâmetros	RGB	NIR	Multiespectral
Inicial (alinhamento)	RMSE	0.041 m	0.041 m	0.196 m
	Tempo	02h:06m:45s	04h:45m:43s	01h:04m:51s
	Imagens alinhadas	554 de 554 (100%)	648 de 648 (100%)	2672 de 2696 (99%)
Densificação nuvem	Tempo Densificação	12h:40m:43s	08h:46m:44s	54m:34s
	Total de 3D pontos	212.753.098	151.654.405	19.307.512
	Densidade de pontos (m ³)	42.14	36.08	1.62
MDS e ortomosaico	Resolução (cm.pixel ⁻¹)	5,95	6,22	12,69
	Tempo para MDS	09h:25m:10s	07h:20m:20s	52m:47s
	Tempo ortomosaico*	01h:34m:14s	01h:47m:31s	01h:17m:31s

* soma do tempo para cada mapa de reflectância no caso da câmera multiespectral.


FONTE: A autora (2018).

FIGURA 23 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA RGB PARA O TALHÃO PINUS 2




FONTE: A autora (2018).

FIGURA 24 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA NIR PARA O TALHÃO PINUS 2



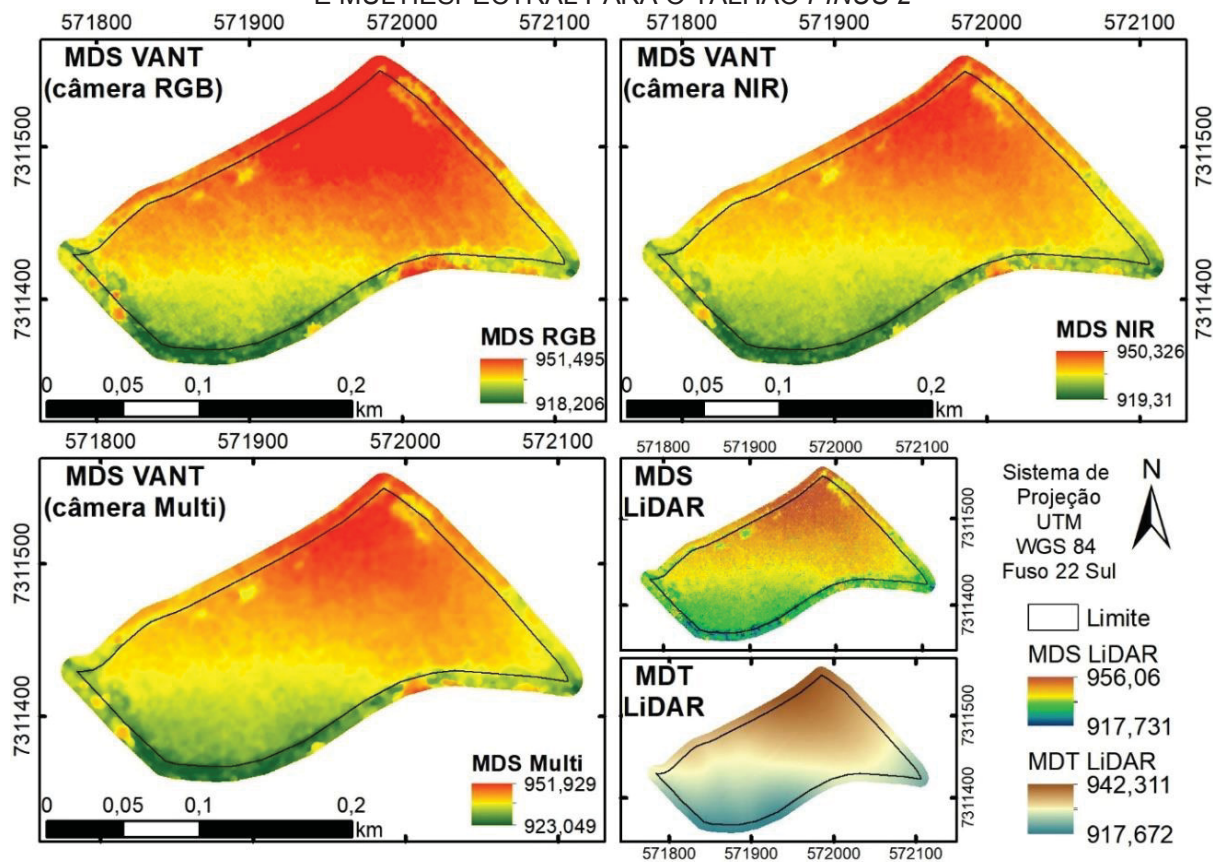
FONTE: A autora (2018).

FIGURA 25 - ORTOMOSAICO GERADO COM AS FOTOGRAFIAS TOMADAS COM A CÂMERA MULTIESPECTRAL PARA O TALHÃO PINUS 2



FONTE: A autora (2018).

FIGURA 26 - MDS GERADOS COM AS FOTOGRAFIAS TOMADAS COM AS CÂMERAS RGB, NIR E MULTIESPECTRAL PARA O TALHÃO PINUS 2



FONTE: A autora (2018).

Os parâmetros das nuvens de ponto que deram origem aos modelos estão apresentados na TABELA 24. A precisão do posicionamento dos ortomosaicos

gerados com as câmeras RGB e NIR estão apresentados na TABELA 25, sendo que para a câmera multiespectral não foi possível a utilização do GPS no dia da coleta desses dados.

TABELA 24 - RESUMO DAS NUVENS VANT E LIDAR UTILIZADAS PARA O TALHÃO *PINUS 2*

Sensor	Banda	Total de pontos	Densidade (m ²)
VANT, câmera RGB	-	199.190.041	76,53
VANT, câmera NIR	-	150.129.153	63,12
VANT, câmera Multiespectral	Verde	4.873.837	4,12
	NIR	4.824.123	4,14
	Red Edge	4.861.196	4,13
	Vermelho	4.748.356	4,03
LiDAR	-	8.739.282	4,03

Fonte: A autora (2018).

TABELA 25 - PRECISÃO DO POSICIONAMENTO DOS ORTOMOSAICOS GERADOS COM AS CÂMERAS RGB E NIR PARA O TALHÃO *PINUS 2*

Pontos	Imagens	Câmera RGB			Imagens	Câmera NIR		
		X	Y	Z		X	Y	Z
1	15	-0,008	0,010	0,028	34	0,004	0,016	0,023
2	18	-0,001	-0,006	-0,025	38	-0,010	-0,016	-0,018
3	44	-0,036	0,063	-0,050	39	-0,040	0,069	-0,071
4	40	0,046	-0,071	0,073	48	0,043	-0,060	0,057
Média (m)	-	0,000	-0,001	0,007	-	-0,001	0,002	-0,002
RMSE (m)	-	0,030	0,048	0,048	-	0,030	0,047	0,048

FONTE: A autora (2018).


Ainda, na FIGURA 27 estão apresentados os posicionamentos dos pontos de controle nos ortomosaicos RGB e NIR, e na TABELA 26 estão apresentadas as comparações entre os valores de elevação obtidos pelo GPS e observados nos MDEs para as posições dos pontos de controle. Os pontos de controle 3 e 4 não estão apresentados nos MDS e MDT LiDAR, porque esses pontos se encontram fora da propriedade da empresa, portanto essa área não foi incluída no levantamento.

TABELA 26 - COMPARAÇÃO ENTRE OS VALORES Z OBTIDOS PARA CADA PONTO DE CONTROLE NOS MDE OBTIDOS POR LIDAR E VANT, PARA OS VOOS REALIZADOS NO TALHÃO *PINUS 2*

Ponto	GPS	MDS VANT RGB		MDS VANT NIR		MDS LiDAR alin.		MDT LiDAR alin.	
		Z	Erro (m)	Z	Erro (m)	Z	Erro (m)	Z	Erro (m)
1	966,30	966,32	-0,02	966,34	-0,05	966,12	0,18	966,10	0,20
2	964,43	964,54	-0,11	964,52	-0,10	965,06	-0,63	965,04	-0,62
3	911,39	911,51	-0,11	911,54	-0,15	-	-	-	-
4	914,34	914,33	0,01	914,41	-0,06	-	-	-	-
Média	-	-	-0,06	-	-0,09	-	-0,23	-	-0,21

FONTE: A autora (2018).

FIGURA 27 - ANÁLISE VISUAL DA QUALIDADE DO POSICIONAMENTO DOS ORTOMOSAICOS PARA OS PONTOS DE CONTROLE, NO TALHÃO *PINUS 2*



FONTE: A autora (2018).

2.4.2 Censo Florestal

No censo florestal realizado foram mensuradas em DAP e altura todas as árvores encontradas nos talhões, com as quais foram calculadas algumas estatísticas básicas dos povoamentos. Na TABELA 27 estão apresentadas as variáveis descritivas dos talhões. Já as distribuições de classes de dap e altura, assim como a relação entre as duas variáveis, estão apresentadas na FIGURA 28.

TABELA 27 - ESTATÍSTICAS DESCRITIVAS DOS DADOS COLETADOS NO CENSO

Parâmetro	<i>Eucalyptus</i>		<i>Pinus 1</i>		<i>Pinus 2</i>	
	dap (cm)	Altura (m)	dap (cm)	Altura (m)	dap (cm)	Altura (m)
Média	18,71	21,15	23,49	16,50	16,07	10,95
Desvio Padrão	2,93	2,16	4,90	2,65	4,00	1,45
Mínimo	5,38	7,90	6,21	6,60	3,09	3,70
Máximo	28,33	28,10	39,15	25,50	30,40	15,80
Número	2.150		2.628		4.257	

FONTE: A autora (2018).

Foram encontrados um total de 2.207 árvores no talhão de *Eucalyptus*, das quais, excluindo-se falhas e árvores quebradas, em 2.150 fustes puderam ser mensurados altura e dap, considerando-se que, para as árvores bifurcadas abaixo do dap, duas medidas foram efetuadas para dap e altura.

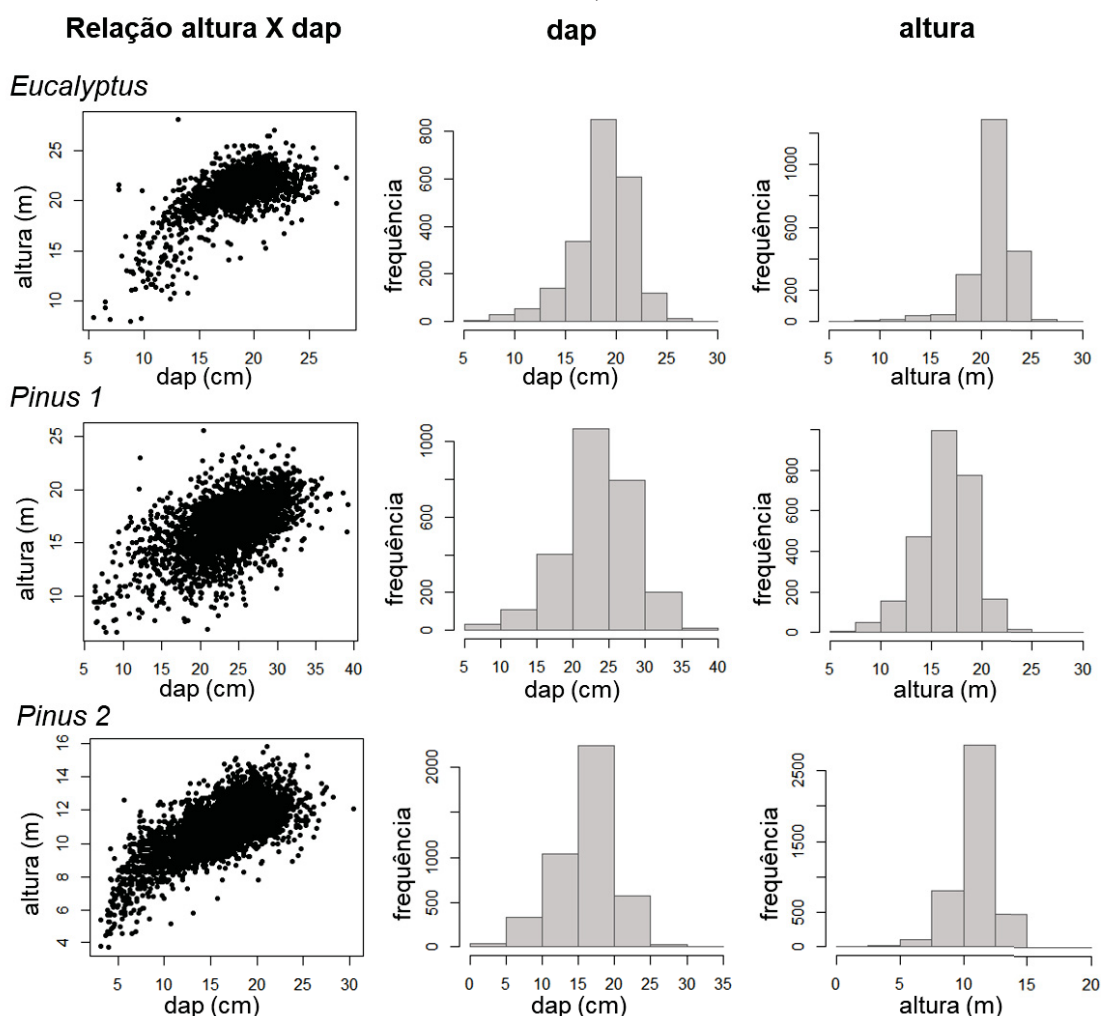
O talhão *Eucalyptus*, apesar de ser o mais novo, apresentou valores de altura superiores aos dos outros talhões, inclusive se comparado com o talhão de *Pinus* com 16 anos (*Pinus 1*). Os valores de dap desse talhão foram também superiores aos

observados no talhão de *Pinus* com 7 anos (*Pinus* 2). A correlação entre os dados de dap e altura no talhão *Eucalyptus* é significativa ($p < 0,05$), com coeficiente de correlação de Pearson de 0,67.

No talhão *Pinus* 1, com a idade mais avançada, foram encontradas 2.888 árvores, das quais 2.628 fustes foram mensurados em altura e dap, e nesse talhão foram observados os maiores valores de dap, com árvores atingindo valores de até 40 cm. A correlação entre os dados de dap e altura é significativa ($p < 0,05$), com coeficiente de correlação de Pearson de 0,57.

Por fim, no talhão *Pinus* 2, das 4.346 árvores, 4.257 foram mensuradas em altura e dap, apresentado, portanto, a maior densidade de árvores. A correlação entre os dados de dap e altura é significativa ($p < 0,05$), com coeficiente de correlação de Pearson de 0,69.

FIGURA 28 - RELAÇÃO ENTRE ALTURA E DAP E DISTRIBUIÇÕES DESSAS VARIÁVEIS PARA OS TALHÕES *EUCALYPTUS*, *PINUS* 1 E *PINUS* 2.



FONTE: A autora (2018).

2.5 DISCUSSÃO

2.5.1 Dados VANT

Dado o processamento das imagens obtidas por VANT, foi possível a obtenção de vários produtos, sendo eles ortomosaicos (para as câmeras NIR e RGB), MDSs (para cada câmera), e nuvens de pontos 3D. Para a câmera multiespectral foram obtidos mapas de reflectância para cada banda espectral, assim como a nuvem de pontos foi gerada para cada banda. No talhão *Eucalyptus* foram obtidos dados somente para as câmeras NIR e multiespectral, com resolução do ortomosaico e MDS de 6,19 cm e 13,29 cm, respectivamente. Para o talhão *Pinus* 1 foram observadas resoluções ligeiramente superiores, de 5,02, 5,33 e 11,72 cm para as câmeras RGB, NIR e Multiespectral, respectivamente. No talhão *Pinus* 2 as resoluções foram de 5,95, 6,22 e 12,69 cm, respectivamente para as câmeras RGB, NIR e Multiespectral.

A explicação das diferenças em resolução entre as câmeras e talhões se dá por variações na altura do VANT no momento do voo, alterações de elevação no terreno, e diferentes tamanhos de sensor. As alterações na altura de voo ocorrem por fatores como vento (ANDERSON; GASTON, 2013), e precisão do GPS embarcado, sendo que a precisão do eBee sem pontos de controle é estimada entre 1-5 m (SENSEFLY LTD, 2014b), e a precisão dos sistemas de localização dos VANTs é normalmente considerada baixa devido ao tamanho reduzido desses (WHITEHEAD; HUGENHOLTZ, 2014). As alterações no terreno causam modificações na escala das imagens, pois alteram a distância entre câmera e objeto mapeado (ALONZO et al., 2018; WOLF; DEWITT; WILKINSON, 2014), portanto é recomendada a utilização de um modelo de terreno para o planejamento do voo, como o que foi utilizado nesse caso. Apesar de o modelo de terreno ter sido utilizado na coleta das imagens, este é baseado em dados como SRTM que tem resolução de 30 m (SENSEFLY LTD, 2014a). Dessa forma, o modelo de terreno tem resolução inferior aos dados coletados com o VANT, e pequenas variações no terreno (menores do que a resolução do MDT) não são levadas em consideração, portanto pequenas diferenças na resolução das imagens não podem ser totalmente eliminadas.

Em ambos as câmeras utilizadas no talhão *Eucalyptus* observou-se que os maiores erros do ajustamento (pelo RMSE total e médio) foram encontrados nas coordenadas Z e X, respectivamente, porém com valores médios aproximados se

comparados a outros estudos em áreas florestais com número similar de pontos de controle (GUERRA-HERNÁNDEZ et al., 2017; TOMAŠTÍK et al., 2017). Apesar disso, a exatidão de produtos derivados de VANTs é bastante variável, sendo encontrados valores de RMSE que variam de metros até centímetros, dependendo de características da área, número de pontos de controle e condições de voo. Exemplos que podem ser citados: RMSE total de 2,94 m utilizando 11 pontos de controle (OTA et al., 2017), RMSE entre 1,77-3,05 m com uso de 5 ou 7 pontos de controle (MLAMBO et al., 2017), RMSE entre 6-8 cm com 4 pontos de controle (AGÜERA-VEGA; CARVAJAL-RAMÍREZ; MARTÍNEZ-CARRICONDO, 2017), RMSE máximo de 25 cm em diferentes configurações de pontos de controle (GERKE; PRZYBILLA, 2016), entre outros. Nos demais talhões, foram observados maiores valores de RMSE na coordenada Z, porém a coordenada X apresentou os menores valores, e de maneira geral, os valores são menores do que observados no talhão *Eucalyptus*. Em todos os talhões, observou-se que o ajuste apresentou valores adequados.

O total de pontos e sua densidade dada por pontos.m⁻³ são muito superiores nas nuvens obtidas por VANT, como observado por Iqbal et al. (2018), Sankey et al. (2017) e Wallace et al. (2016). As nuvens derivadas de VANT apresentam maior densidade de pontos no talhão *Eucalyptus*, seguido pelo talhão *Pinus 1* e *Pinus 2*, sendo que no primeiro observa-se praticamente o dobro da densidade de pontos dos outros dois (150 pontos.m⁻²). Esse mesmo padrão é observado nas nuvens LiDAR, em que no talhão *Eucalyptus* se observa uma densidade de 9 pontos.m⁻², enquanto que nos demais talhões é de aproximadamente 5 e 4 pontos.m⁻², respectivamente para *Pinus 1* e 2. Esse padrão pode estar relacionado ao tipo de cobertura do solo nesse talhão, que apresenta árvores mais espaçadas e textura mais complexa, o que tende a produzir maior densidade de pontos em nuvens VANT (BEMIS et al., 2014; IQBAL et al., 2018). Da mesma forma, a maior densidade da floresta altera a capacidade de penetração dos pontos LiDAR na floresta, principalmente em relação ao número de pontos que conseguem atingir o solo (HANSEN; GOBAKKEN; NÆSSET, 2015). As nuvens derivadas da câmera multiespectral apresentam menor número e densidade de pontos porque cada banda é processada separadamente, e porque para essa câmera foi escolhida a opção de densidade *Optimal* na etapa de densificação da nuvem de pontos.

A densidade do LiDAR, variando de 4-9 pontos.m⁻², pode ser considerada média, haja vista que dados ALS apresentam densidades que variam de 0,5–40

pontos.m⁻². A densidade de pontos adequada é variável em cada aplicação, sendo que, quando se objetiva a identificação de árvore individualmente, densidades acima de 5 pulsos.m⁻² são recomendadas, porém em casos em que são realizadas estimativas de parâmetros por área, menores densidades são suficientes (WHITE et al., 2016). Nessas circunstâncias, Hansen, Gobakken e Næsset (2015) avaliaram a redução da densidade de pulsos (pulsos emitidos que podem ter mais de um retorno) por m² para obtenção de MDT e concluíram que a redução de 8 para 0,25 pulsos.m⁻² não afeta significativamente a geração de MDT.

Os valores de elevação nos MDS obtidos com VANT são bastante próximos entre si, considerando-se as diferentes câmeras para os três talhões, com variações que podem ser explicadas pelas características das câmeras e diferença de resolução. O MDS derivado de VANT que mais se diferenciou dos demais MDS VANT foi obtido a partir das imagens multiespectrais no talhão *Pinus 2*, apresentando valores de elevação mínima superiores aos demais MDS (923 m comparados com 918 e 919 m das câmeras RGB e NIR, respectivamente). Essa diferença pode ser dada pela resolução do MDS, menor que dos demais, e que, portanto, pode ocultar pequenas variações de elevações na área, como observado em MDS LiDAR (STEREŃCZAK; BĘDKOWSKI; WEINACKER, 2008), assim como pela falta de pontos de controle no processamento das imagens multiespectrais no talhão *Pinus 2*.

A análise dos MDS também permite verificar que há similaridade entre os MDS VANT e MDS LiDAR, porém em todos os casos o MDS LiDAR apresenta valores de elevação máxima superiores, devido ao crescimento das árvores no período entre as coletas (VANT em 2015 e LiDAR em 2017). Os valores de elevação mínima em geral são similares, e correspondentes aos valores observados nos MDTs. O talhão *Pinus 1* apresentou distinção, sendo que no MDS LiDAR observam-se valores de elevação muito abaixo dos observados nos MDS VANT (925,075 m comparados com 935,906 m observado no MDS RGB). Nesse caso, foi realizada uma análise do MDS e da nuvem de pontos e observou-se que o LiDAR retornou vários pontos no solo, mesmo na floresta densa, possivelmente devido às aberturas na copa resultantes de copas danificadas pelos macacos. Devido a esses pontos, e a densidade de pontos do LiDAR, várias células no interior do talhão correspondem à elevação no nível do solo, portanto os valores baixos de altitude são reais, e correspondem aos valores encontrados no MDT LiDAR. Destaca-se que em alguns casos ocorre a suavização

de pequenas aberturas na copa em MDS derivado de VANT em comparação com MDS LiDAR (GAŠPAROVIĆ et al., 2017).

A qualidade do posicionamento dos produtos VANT é principalmente importante devido à necessidade de utilização dos dados VANT em conjunto com os de outra fonte para detecção do terreno, visto que o encobrimento do solo é uma das principais limitações da técnica VANT-SfM em áreas de cobertura florestal (TOMAŠTÍK et al., 2017; ZAHAWI et al., 2015). Dessa forma, além da análise do ajustamento, o posicionamento dos pontos de controle foi avaliado, e observou-se um posicionamento adequado tanto horizontalmente, dado pela sobreposição dos pontos sobre o ortomosaico, quanto verticalmente, dado pela comparação entre os valores de elevação nos MDS e os pontos de controle. Na análise horizontal, observou-se que, de maneira geral, existe maior deslocamento do ponto em relação ao centro do alvo nos produtos derivados da câmera multiespectral. Esses são em escala pequena e explicados devido à maior dificuldade de marcação dos pontos de controle nessas imagens, principalmente devido à reflectância do sol no alvo e à menor qualidade geométrica dessa câmera, apresenta apenas 1,2 MP (SENSEFLY LTD, 2014c).

O único talhão que apresentou discrepâncias de posicionamento vertical entre as nuvens de ponto VANT foi o *Pinus* 1, em que a nuvem RGB revelou diferenças de elevação. Além disso, neste trabalho, observou-se que haviam discrepâncias entre a altitude das nuvens de pontos derivadas de VANT e da nuvem do LiDAR. Dado que os dados VANT estavam coerentes com os pontos de controle, foi realizado o ajuste da nuvem do LiDAR em relação à uma determinada nuvem VANT. Após o ajustamento, observou-se que as nuvens estavam próximas, apesar dos dados do LiDAR apresentarem, ainda assim, maior discrepância em relação aos pontos de controle, para todos os talhões. As diferenças entre as nuvens de pontos podem ser de diversas origens, entre elas a resolução e precisão distinta de cada sistema (IQBAL et al., 2018). Dessa maneira, o alinhamento de dados de diferentes fontes é uma prática comum e uma das mais importantes etapas para posteriores fusões ou análises integradas (MESSINGER; ASNER; SILMAN, 2016; YANG; CHEN, 2015).

Conforme destacado, o posicionamento da nuvem de pontos gerada com a câmera RGB no talhão *Pinus* 1 apresentou erros de posicionamento em elevação, provavelmente devido à baixa exatidão dos pontos de controle coletados no dia, visto que esses tem fundamental importância na exatidão do georreferenciamento (WOLF;

DEWITT; WILKINSON, 2014). Dessa maneira, essa nuvem foi realinhada em relação à nuvem NIR, e, portanto, a comparação com os pontos de controle não é mais válida, de forma que foi analisada a relação entre o MDS RGB e os MDT e MDS LiDAR em relação aos produtos obtidos com a câmera NIR. Nesse caso, também observa-se maiores divergências entre os valores de LiDAR, sendo que em um dos pontos observa-se uma diferença de mais de 12 m, justificada pelo fato de a localização desse ponto de controle ser muito próxima a um talhão no qual se tinha efetuado o corte no momento da realização dos voos VANT, porém havia sido replantado logo após, sendo que no momento de aquisição dos dados LiDAR, as árvores de *Eucalyptus* já apresentavam grande altura.

2.5.2 Caracterização dos talhões

Dados os valores estatísticos apresentados sobre os talhões, observa-se que o talhão *Eucalyptus* apresenta ótimo crescimento, com valores de diâmetro superiores ao talhão de *Pinus* com 7 anos, e valores de altura superiores a ambos os talhões de *Pinus* com 7 e 16 anos de idade. Segundo Baldrati (2015), o híbrido *Eucalyptus urograndis* é recomendado para plantio na região dos Campos Gerais do Paraná e apresenta propriedades favoráveis devido à combinação de alto crescimento e qualidade da madeira do *E. grandis*, com a adaptabilidade e resistência do *E. urophylla*. Os valores encontrados neste estudo são coerentes e ligeiramente superiores aos valores de dap e altura médios de 12,37 cm e 18,30 m aos 4,5 anos de idade em Goiás (RODRIGUES et al., 2013), porém inferiores aos valores de dap e altura média aos 3,5 anos de idade observados por Baldrati (2015), de 16 cm e 18,02 m em região de Campos Gerais Paranaense.

Dentre os talhões de *Pinus*, pode-se dizer que o talhão mais jovem (7 anos) apresenta condições normais para a idade, quando comparada a altura média de 9,82 m para essa idade e mesma região observada por Loureiro (2016), assim como os valores de DAP e altura média aos 6 anos observados por Souza e Fiorentin, (2015), de 14,53 cm e 9,65 m respectivamente.

O talhão com idade mais avançada (16 anos), por outro lado, apresenta valores de altura média abaixo do observado por Loureiro (2016) de 19,16 m. Esse menor valor de altura média no talhão com 16 anos pode ser relacionado com a presença de danos causados pelos ataques de macaco-prego observado nesse

talhão. O talhão mais jovem não apresenta ataques ainda, possivelmente devido à localização, ou mesmo a idade, sendo que os ataques normalmente só ocorrem a partir dos 6 anos de idade (LIEBSCH et al., 2015).

A menor altura no talhão atacado se baseia em análises que comprovam que os danos causados pela abertura da casca das árvores causam diminuição de crescimento em dap (LIEBSCH et al., 2015), e volume (LIEBSCH et al., 2018). Além disso, após o janelamento ou anelamento, é comum o crescimento de galhos laterais e bifurcações, cuja madeira apresenta qualidade inferior (LIEBSCH et al., 2018). Ainda, observa-se que os percentuais de mortalidade desse talhão são maiores do que nos demais, e principalmente de árvores quebradas, fato também relacionado aos ataques de macaco-prego (MIRANDA, 2016). Os percentuais de árvores atacadas no talhão *Pinus 1* (cerca de 77,9%), corroboram com os valores encontrados em outros estudos, como os 80,3% de ataque observado em parcelas de *Pinus taeda* em plantios no Paraná e Santa Catarina (LIEBSCH; MIKICH, 2017).

2.6 CONCLUSÕES

Os ortomosaicos, modelos de superfície e nuvens de pontos obtidos a partir do processamento dos dados obtidos por plataforma VANT e diferentes câmeras apresentam alta resolução, e de acordo com as análises de qualidade, apresentam posicionamento espacial apropriado.

A utilização dos produtos VANT em conjunto com os modelos de terreno obtidos pelo *laser* foi considerada apropriada, dado o alinhamento dos dados do LiDAR.

Os talhões avaliados apresentam crescimento similar a valores encontrados em outros estudos para as espécies e idades selecionadas na maior parte dos casos, com variações explicadas pelos parâmetros avaliados em campo.

Danos nas árvores de um dos talhões, causados por macaco-prego, foram possíveis de ser avaliadas com os dados coletados em campo.

CAPÍTULO 3: DETECÇÃO AUTOMÁTICA DE ÁRVORES A PARTIR DE IMAGENS OBTIDAS POR MEIO DE VEÍCULO AÉREO NÃO TRIPULADO

3.1 INTRODUÇÃO

O uso de informações obtidas por sensoriamento remoto (SR) em atividades relacionadas ao manejo florestal é uma prática comum (TANG; SHAO, 2015), visto que o SR permite a obtenção de uma grande quantidade de informações relativas ao ambiente em estudo sem grande esforço de campo. Grande parte das aplicações desses dados foi originalmente restrita à estimativas em nível de área, devido à familiaridade de incorporação desses tipos de técnicas aos tradicionais levantamentos em campo, e das restrições de custo associadas à altas resoluções necessárias para trabalhos de modelagem em níveis de árvore (WHITE et al., 2016; WULDER et al., 2012). Apesar disso, modelos baseados em níveis de árvore tendem a apresentar relação biológica mais forte e melhores resultados (HYYPÄ et al., 2008; LISEIN et al., 2013) quando a detecção é bem sucedida. Outra questão que inibiu o uso de dados de SR em certas atividades do manejo florestal é o limitado recobrimento temporal associado às condições climáticas para coleta de dados com sensores passivos (TANG; SHAO, 2015), pois, principalmente no caso de florestas plantadas com crescimento rápido, é importante a obtenção de informações sobre o povoamento em períodos específicos para avaliar o desenvolvimento da floresta. Dessa forma, apesar do grande interesse do uso de dados SR para aplicações florestais de precisão, as primeiras plataformas existentes não permitiam a execução de muitas das aplicações desejadas.

O desenvolvimento dos Veículos Aéreos Não Tripulados (VANTs), na última década permitiu a obtenção de dados de SR com várias vantagens comparadas às tradicionais plataformas, como satélites e aeronaves tripuladas. Essas vantagens se referem ao baixo custo em relação à tecnologias similares em termos de resolução e dados obtidos (PÁDUA et al., 2017; WHITEHEAD et al., 2014), a capacidade de uso desses veículos aéreos com diversos sensores de acordo com a aplicação (PÁDUA et al., 2017; TANG; SHAO, 2015) e a flexibilidade na escolha de data de aquisição, devido à simplificada operação desses veículos aéreos (WHITEHEAD et al., 2014), entre outras.

Dadas essas características, os dados obtidos com VANT rapidamente começaram a ser aplicados em atividades ligadas ao setor florestal, incluindo atividades com alto grau de detalhamento, como a detecção de árvores individuais (BONNET; LISEIN; LEJEUNE, 2017; MOHAN et al., 2017; NEVALAINEN et al., 2017) e subsequentes modelagens a partir dessas.

Com relação ao custo de obtenção de dados, é importante destacar que, apesar de os veículos aéreos e sistema VANT em si serem muito mais econômicos comparados com plataformas tradicionais, o tipo de sensor escolhido é de grande importância, pois os sensores ativos do tipo LiDAR ainda são caros comparados ao uso de sensores passivos. Nesse sentido, a maior parte das aplicações de VANT na área florestal ainda são derivadas de sensores passivos, principalmente a região do visível (RGB) ou com bandas na região do infravermelho (TANG; SHAO, 2015; TORRESAN et al., 2017).

O uso desses sensores passivos para diversas aplicações também se deve ao desenvolvimento do processamento de imagens com aplicação de técnicas de visão computacional, conhecidas como *Structure from Motion* (SfM) e *Multi View Stereo* (MVS) integradas em um processo conhecido como *Bundle Adjustment* (BA) (CARRIVICK; SMITH; QUINCEY, 2016). O uso dessas técnicas permite calcular a posição e os parâmetros de orientação das câmeras, além de recriar a posição dessas feições em uma nuvem de pontos 3D a partir do movimento dessas feições detectadas em imagens com regiões sobrepostas (CARRIVICK; SMITH; QUINCEY, 2016; VERHOEVEN, 2011). Esse sistema de processamento permitiu a utilização de câmeras comuns sem calibração (CARRIVICK; SMITH; QUINCEY, 2016), pois os parâmetros de calibração da câmera são calculados durante o processo, e a obtenção não somente de ortomosaicos como também de estruturas tridimensionais, como nuvens de pontos e modelos digitais de superfície (WHITEHEAD; HUGENHOLTZ, 2014). Dadas as características de custo e produtos obtidos, o uso de VANTs com sensores passivos foram abordados neste trabalho.

Apesar dessas características muito úteis ao setor florestal, existem também desafios relacionados à utilização dos dados derivados de VANT, visto que a alta resolução das imagens reflete em altas variações espectrais, de formas e de textura para o mesmo objeto ou para seus similares, causando dificuldade na aplicação de alguns dos mais tradicionais métodos de classificação de imagens (FRANKLIN; AHMED, 2017; KE; QUACKENBUSH, 2011). Existem alguns métodos de

processamento de imagens que podem ser úteis no processo de obtenção da informação desejada, como o uso de técnicas de realce para aumentar a distinção entre objetos distintos, a seleção de banda ou combinação mais adequada ao alvo de interesse, aplicação de correções radiométrica e/ou atmosférica, além do uso de técnicas de suavização e reamostragem (KE; QUACKENBUSH, 2011). Dentre as técnicas mais utilizadas com imagens de alta resolução está o uso de segmentação e de classificações orientadas ao objeto (OBIA – *Object-based Image Analysis*) (BAENA et al., 2017). O uso de técnicas OBIA tem como vantagens, quando comparadas às técnicas de pixel, a simplificação da imagem em áreas homogêneas e o cálculo de um grande número de descritores espectrais úteis no processo de classificação (BLASCHKE, 2010). Apesar disso, a aplicação dessas técnicas em imagens VANT ainda é limitada, principalmente devido à grande variação de padrões espectrais dependendo do sensor utilizado e de condições de luminosidade.

Uma outra alternativa é a utilização de algoritmos baseados na estrutura 3D da floresta, como os desenvolvidos para dados do LiDAR aerotransportado (ALS), dado que as técnicas de processamento das imagens VANT permitem a obtenção de modelos de superfície da floresta. Dentre os algoritmos disponíveis, os mais populares são baseados na detecção dos picos máximos em um Modelo Digital de Altura de Copa (CHM), chamados de Locais Máximos (ou *local maxima*), com variações em termos de tamanho de janelas, suavização e pós-processamento (VAUHKONEN et al., 2012). Ainda é possível a utilização de segmentações da nuvem de pontos, segmentações de bacias, segmentação adaptativa, crescimento de regiões, de detecção de bordas no CHM, espaço *Voxel*, entre outros (FAVORSKAYA; JAIN, 2017; VAUHKONEN et al., 2012).

Também é possível a utilização de técnicas que se baseiam em ambas informações espectral e estrutural, em alguns casos aplicadas em fusões entre dados ALS e imagens (KOUKOULAS; BLACKBURN, 2005; LECKIE et al., 2003), dada a obtenção de ambas informações a partir das mesmas imagens durante o processamento das imagens VANT com o SfM. Até o momento, os principais trabalhos com aplicações de imagens VANT para detecção de árvores foram desenvolvidos aplicando-se as técnicas de Locais Máximos (BIRDAL; AVDAN; TÜRK, 2017; BONNET; LISEIN; LEJEUNE, 2017; GOODBODY et al., 2017; MOHAN et al., 2017; NEVALAINEN et al., 2017), e OBIA em imagens, CHMs ou combinações (BAENA et al., 2017; FRANKLIN; AHMED, 2017; GUERRA-HERNÁNDEZ et al.,

2017). As principais limitações do uso das técnicas OBIA referem-se à alta resolução dos dados VANT e de padrões de iluminação muitas vezes inconsistentes, que causam dificuldade na segmentação e classificação devido à heterogeneidade que os objetos apresentam (FRANKLIN; AHMED, 2017). Já nos métodos baseados em estrutura, como os Locais Máximos, existe a dependência da existência de um Modelo Digital do Terreno (MDT) para gerar um modelo de altura de copa, o que dificilmente é possível de ser obtido em florestas adultas com sensores passivos, de forma que depende da existência de MDT de outra fonte (BONNET; LISEIN; LEJEUNE, 2017; LISEIN et al., 2013). Ainda, é comum que ocorra a suavização de topos de árvores em CHM de imagem, dificultando a detecção de picos (BONNET; LISEIN; LEJEUNE, 2017).

Considerando-se o exposto, neste capítulo buscou-se o desenvolvimento e a aplicação de uma ferramenta para detecção de árvores com foco em dados VANT. A ferramenta desenvolvida é baseada nas técnicas de segmentação de bacias e foi desenvolvida em ambiente Python. A apresentação da ferramenta e resultados parciais em algumas áreas testes foram apresentados em Hentz et al. (2018), porém detalhes da avaliação da qualidade dos resultados e comparações com outros algoritmos serão apresentados a seguir.

3.2 OBJETIVOS

O objetivo geral deste capítulo foi criar uma ferramenta para detecção de árvores individuais a partir de dados obtidos por meio de plataforma VANT embarcada com sensor passivo, com a mínima necessidade de iterações do usuário.

Os objetivos específicos são:

- Criar uma ferramenta de detecção que possa ser aplicada nos produtos derivados de imagens obtidas por câmera passiva em VANT;
- Realizar a detecção de árvores utilizando algoritmos já implementados na literatura, baseados em diferentes técnicas de detecção;
- Avaliar a precisão da ferramenta criada, e compará-la com os resultados de outros métodos de detecção.

3.3 MATERIAL E MÉTODOS

3.3.1 Área de estudo

A área de estudo utilizada neste capítulo representa os três talhões descritos no capítulo 2, compostos de um talhão de *Eucalyptus urograndis* com 5 anos de idade (*Eucalyptus*), um talhão de *Pinus taeda* com 16 anos de idade (*Pinus* 1), e um talhão de *Pinus taeda* com 7 anos de idade (*Pinus* 2).

3.3.2 Material

O material utilizado para a criação da ferramenta e da sua comparação com outros algoritmos compreende tanto os aplicativos computacionais que envolvem cada método de detecção, como os arquivos de entrada para teste deles.

Na avaliação dos métodos foram utilizados os dados obtidos por VANT para cada talhão. A descrição do sistema VANT, da coleta dos dados e do processamento para a obtenção dos produtos VANT (ortomosaico, MDS e nuvem de pontos), assim como do alinhamento com os dados do LiDAR, foram apresentados no Capítulo 2.

Dada a disponibilidade de três distintas câmeras na coleta VANT, optou-se pela utilização de apenas uma no processo de detecção das árvores, afim de limitar a influência das diferenças de câmeras nos resultados. Para tanto, a câmera selecionada foi a NIR, pois foi utilizada em todos os talhões, e em todos os casos foram coletados pontos de controle precisos. Dessa forma, no presente capítulo, a menção de dados VANT serão referentes à câmera NIR. A câmera em questão é do modelo S110 NIR, tem um sensor de 4000 x 3000 pixels, distância focal de 5 mm, resolução de 180 dpi (12 MP) e opera nas bandas verde, vermelho e NIR. Maiores detalhes sobre a câmera e a plataforma VANT podem ser obtidos no capítulo 2.

Ainda, em muitos dos métodos que serão apresentados, será necessário o uso de um CHM (*canopy height model*) ou nuvem de pontos VANT normalizada e dado que não é possível a geração de um MDT oriundo de plataforma VANT com sensor passivo nas condições dos talhões utilizados, a nuvem de pontos VANT foi normalizada com o MDT derivado dos dados do LiDAR. A normalização e a geração do CHM, quando necessária, foram realizados com o *software* Fusion versão 3.70 (MCGAUGHEY, 2018).

3.3.3 Métodos para detecção automática de árvores

O principal foco deste capítulo foi a criação de uma ferramenta para detecção de árvores a partir de dados VANT, porém, de forma a avaliar a capacidade dessa ferramenta frente a outros métodos (algoritmos, *softwares*), a detecção também foi realizada utilizando-se de outros três métodos, descritos adiante. Dessa forma, na sequência serão apresentados o desenvolvimento da ferramenta proposta, assim como a descrição dos parâmetros utilizados para a detecção em cada método.

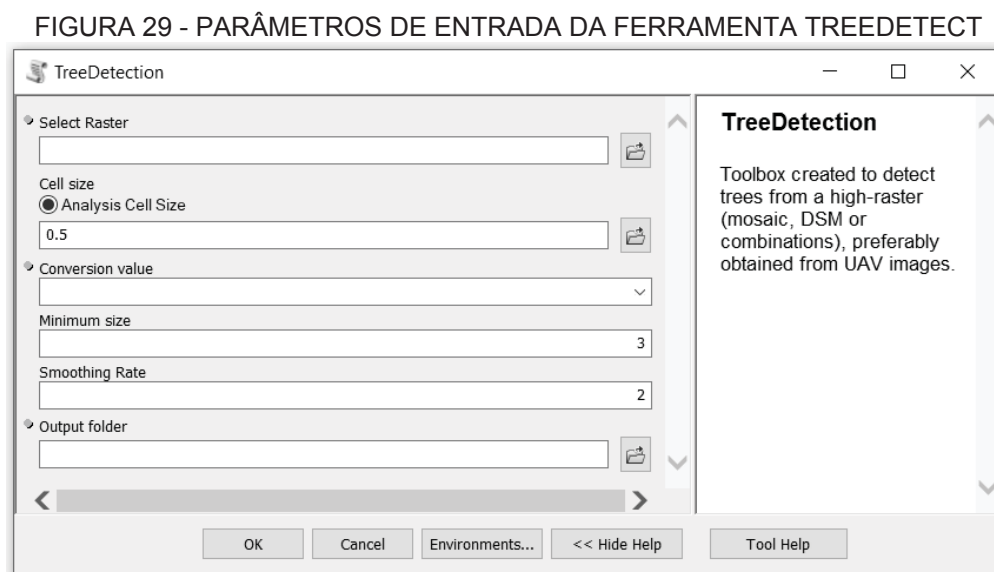
3.3.4 Desenvolvimento da ferramenta TreeDetect

A ferramenta TreeDetect foi criada dentro de uma caixa de ferramenta denominada de TreeDetection, escrita em linguagem Python para ArcGIS (ArcPy). A ferramenta foi criada pela integração de diversas funções implementadas no ArcGIS, cujo código está disponível em ArcPy.

Conforme destacado, a criação da ferramenta exige também a criação de uma caixa de ferramentas, onde essa e outras serão armazenadas. A caixa de ferramentas apresenta uma seção geral, chamada *init*, em que são definidos o nome da caixa de ferramentas e a listagem das ferramentas incluídas na caixa. Em cada ferramenta são necessárias pelo menos duas seções obrigatórias e podem haver mais quatro partes opcionais. As seções obrigatórias são *init*, na qual se inserem o nome da ferramenta e descrições, e *execute*, na qual os códigos de execução propriamente ditos são inseridos. As seções opcionais são *getParameterInfo*, no qual são definidos os parâmetros (de entrada e saída por exemplo) necessários para execução da ferramenta, *isLicensed*, para se verificar se todas as licenças necessárias estão disponíveis, *updateParameters*, que apresenta a opção de atualizar os parâmetros a cada iteração e *updateMessages* para atualizar as mensagens a cada atualização dos parâmetros. Para a ferramenta em questão, as seções de interesse são as de definição dos parâmetros (*getParameterInfo*), e de execução do código (*execute*), descritas na sequência, ainda que na seção *init* tenham sido inseridas as informações de nome e descrição da ferramenta.

3.3.4.1 Definição de parâmetros

Para a execução de qualquer ferramenta é necessária a definição de alguns parâmetros. Esses parâmetros podem ser obrigatórios ou opcionais, de entrada ou de saída, e podem apresentar um valor *default* (padrão) que será utilizado caso o usuário não altere o valor. Nesse particular caso, foram definidos no total seis parâmetros, sendo cinco de entrada e um de saída, conforme está apresentado na FIGURA 29.



FONTE: A autora (2018).

O primeiro parâmetro de entrada é a seleção do **arquivo de entrada**, em formato *raster*, que será utilizado para a detecção das árvores, definido como obrigatório. Esse arquivo foi idealizado para ser um ortomosaico ou outro produto derivado de plataforma VANT com câmera passiva, com alta resolução. Além do ortomosaico podem ser utilizadas bandas individuais, matemática de bandas (combinações de soma, multiplicação, entre outras), índices de vegetação, e produtos relativos à valores de elevação, como um CHM, ou até mesmo um MDS em áreas planas.

Quando for selecionado um arquivo composto de múltiplas bandas (um ortomosaico) o processamento será dado com base na primeira banda disponível, porém se for de desejo do usuário utilizar a informação de todas as bandas, essas podem ser combinadas por meio de matemática de bandas. Essa informação, assim como detalhes para cada parâmetro, é apresentada na janela de interface no momento em que cada opção é selecionada.

O segundo parâmetro, também de entrada, é o **tamanho de célula** que será utilizado durante o processamento. Esse parâmetro tem um valor *default* de 0,5 m,

portanto é opcional a seleção de outro valor. De maneira geral, o uso de uma resolução menor suavizará pequenas diferenças e agilizará o processo.

O terceiro parâmetro é o **fator de conversão**, obrigatório, e que apresenta duas opções de escolha, +1 ou -1. Quando for selecionado o valor de +1 no fator de conversão, não será realizada qualquer alteração no arquivo de entrada, já se for selecionado -1, o raster de entrada terá sua estrutura invertida. Por exemplo, se o raster de entrada for um CHM, o topo das árvores resultará em valores de elevação mais altos do que o restante da cena no arquivo original, porém para a aplicação da segmentação de bacias, é desejável que os valores de altitude nos topos sejam menores, portanto deve-se utilizar o fator -1 para fazer a inversão. Em caso da utilização de um ortomosaico, deve-se atentar para os valores de número digital dos pixels para se decidir se é apropriada a decisão de se ter a inversão ou não dos valores.

O quarto parâmetro é o **tamanho mínimo**, que representa, aproximadamente, o menor tamanho que uma copa de árvore apresentará na condição da floresta presente na imagem. O valor selecionado é utilizado em uma função que irá excluir as áreas menores que este determinado valor. Isso é importante para evitar que pequenas alterações espectrais ou estruturais, como a presença de galhos, sejam detectados como árvores. Esse parâmetro é opcional, e em casos não definidos pelo usuário, o valor *default* 3 m² será utilizado.

A **taxa de suavização** é o quinto parâmetro de entrada, que se refere ao número de células vizinhas utilizadas no processo de suavização do arquivo de entrada. É também opcional e tem um valor *default* de 2 células. Sugere-se que o valor escolhido seja pequeno em áreas homogêneas, e maior em áreas heterogêneas, como em florestas naturais com alta diversidade de espécies, quando utilizado um arquivo de entrada relativo à resposta espectral da floresta.

O último parâmetro, e único de saída, é a **pasta de saída**, onde serão armazenados os arquivos produzidos durante o processamento, e o arquivo final de árvores detectadas. Definiu-se que a pasta de saída deve ser um *geodatabase* (gdb), pois esse tipo de pasta armazena os arquivos em um formato que não apresenta problemas quanto à sua extensão, como acontece em muitos casos quando se trabalha com *shapefile*. O sumário dos parâmetros está apresentado na TABELA 28.

Apesar de existirem valores *default* e algumas indicações da escolha dos mesmos, é importante que se façam testes de otimização desses parâmetros para

cada caso, com especial atenção para os parâmetros de tamanho mínimo e taxa de suavização.

TABELA 28 - SUMÁRIO DOS PARÂMETROS DA FERRAMENTA TREEDTECT

Parâmetro	Categoria	Tipo	Padrão	Uso
1 Seleção do arquivo <i>raster</i>	Entrada	Obrigatório	-	Seleção do arquivo matricial de entrada.
2 Tamanho de célula	Entrada	Opcional	0,5	Permite ao usuário definir a resolução.
3 Fator de conversão	Entrada	Obrigatório	-	Valor utilizado para inverter a estrutura antes da segmentação de bacias.
4 Tamanho mínimo	Entrada	Opcional	3	Valor utilizado para excluir segmentos muito pequenos.
5 Taxa de suavização	Entrada	Opcional	2	Valor que suaviza diferenças muito grandes no arquivo de entrada.
6 Pasta de saída	Saída	Obrigatório	-	Pasta onde serão armazenados os arquivos de saída.

FONTE: A autora (2018).

3.3.4.2 Execução

A ferramenta TreeDetect foi elaborada pela combinação de diversas ferramentas disponíveis no *software* ArcGIS a partir de algumas extensões (principalmente da *Spatial Analyst*). Essas ferramentas estão apresentadas na TABELA 29 e suas aplicações no contexto da ferramenta TreeDetect serão apresentadas na sequência.

TABELA 29 - FERRAMENTAS UTILIZADAS NO CONTEXTO DA FERRAMENTA TREEDTECT

Ferramenta	Extensão	Entrada (s)	Saída
<i>Times</i>	<i>Spatial Analyst</i> ou <i>3D Analyst</i>	Parâmetros 1 e 3	Raster times
<i>Focal statistics</i>	<i>Spatial Analyst</i>	Raster times, e parâmetros 2 e 5	Raster focal
<i>Flow direction</i>	<i>Spatial Analyst</i>	Raster focal	Raster fluxo
<i>Basin</i>	<i>Spatial Analyst</i>	Raster fluxo	Áreas
<i>Raster to polygon</i>	<i>Conversion</i>	Áreas	Áreas shp
<i>Select</i>	<i>Analysis</i>	Áreas shp e parâmetro 4	Área de copas
<i>Zonal statistics</i>	<i>Spatial Analyst</i> ou <i>3D Analyst</i>	Área de copas e raster focal	Raster mínimo
<i>Equal to</i>	<i>Spatial Analyst</i>	Raster mínimo e raster focal	Valores mínimos
<i>Reclassify</i>	<i>Spatial Analyst</i> ou <i>3D Analyst</i>	Valores mínimos	Árvores
<i>Raster to point</i>	<i>Conversion</i>	Árvores	Árvores shp
<i>Intersect</i>	<i>Analysis</i>	Árvores shp e Área de copas	Árvores detectadas
<i>Delete identical</i>	<i>Data Management</i>	Árvores detectadas	Árvores detectadas

FONTE: A autora (2018).

A primeira ferramenta executada no processo é a **Times**, que realiza a multiplicação de um arquivo *raster*, nesse caso o arquivo selecionado como parâmetro

de entrada 1, com um determinado valor definido, nesse caso o fator de conversão (parâmetro 3). Conforme destacado, se o valor do fator de conversão selecionado for -1, o *raster* será invertido, e em caso de seleção do valor 1, o *raster* permanecerá com as mesmas características. O resultado dessa ferramenta é denominado *raster times*.

A próxima ferramenta aplicada é a **Focal Statistics**, que é utilizada para ressaltar os pixels com menores valores (topos). Para tanto, o valor mínimo em um raio de células, definidas no parâmetro taxa de suavização (parâmetro 5), será aplicado a todos os pixels desse raio. Nessa etapa também é utilizado o parâmetro 2 (tamanho de célula) que irá padronizar a resolução utilizada. O resultado é denominado *raster focal*.

Na sequência do processo, a ferramenta **Flow Direction** é aplicada no *raster focal*, e resultará em um arquivo também *raster*, mas que representa a direção de fluxo de cada célula (ARCGIS, 2017), chamado raster fluxo. A partir do *raster* de direção de fluxo, a ferramenta **Basin** é aplicada para a delimitação das áreas de drenagem, que nesse caso correspondem às áreas de copas de cada árvore. Essa é a ferramenta que compreende o processo de segmentação de bacias. Esse processo resultará, portanto, em um arquivo *raster* que compreende áreas que se aproximam das copas das árvores, porém não com o limite exato dessas, pois podem haver áreas de solo, por exemplo, entre as copas. Esses segmentos são denominados de *Áreas*. Os resultados dessa segmentação são então convertidos para o formato vetorial com a ferramenta **Raster to polygon** e são denominados de *Áreas shp*. Na sequência, as áreas muito pequenas são excluídas a partir da ferramenta **Select** aplicada no arquivo de copas em formato vetorial. O resultado desse processo será as copas de árvores (aproximadamente) acima do limite mínimo definido, denominadas de *Áreas de copas*.

A próxima ferramenta utilizada é a **Zonal Statistics**, que encontrará os valores mínimos para cada área de copa definida no processo anterior. Os valores serão referentes ao *raster* com os valores mínimos ressaltados (*raster focal*). Esse processo resultará num *raster* que apresenta cada área de copa com todos os pixels, representando esse valor mínimo encontrado (raster mínimo). A ferramenta **Equal to** então é utilizada, permitindo identificar as células que apresentam os mesmos valores nos arquivos raster focal e raster mínimo, que correspondem aos topos das árvores. O resultado dessa ferramenta é um raster (*valores mínimos*) com valores 1 ou 0, sendo 1 os topos e 0 o restante. As células com valor 0 são então convertidas para NoData (célula vazia) com a ferramenta **Reclassify**, resultando em um arquivo que

corresponde só aos valores das árvores (chamado de *Árvores*). Esses pixels são convertidos para vetor de ponto com a ferramenta ***Raster to point*** (*Árvores shp*).

As últimas etapas removerão pontos extras detectados, como quando uma área de copa tem vários pixels com o mesmo valor mínimo. Para tanto, o número identificador de cada bacia é incorporado no arquivo de pontos gerado anteriormente (*Árvores shp*), utilizando a ferramenta ***Intersect*** e gerando o arquivo *Árvores detectadas*. Posteriormente, a ferramenta ***Delete identical*** irá remover todos os pontos que apresentarem valores repetidos, com referência ao número de cada bacia. Dessa forma, somente um ponto poderá ser encontrado relativo a cada área de copa.

Após a execução do processo em si, o arquivo das árvores detectadas é automaticamente incorporado ao projeto ArcGIS utilizado e os demais arquivos gerados estarão disponíveis na pasta de saída selecionada no parâmetro 6 para possíveis consultas.

3.3.5 Algoritmos aplicados para a detecção

A detecção das árvores nos três talhões de estudo foi realizada com a ferramenta proposta em duas configurações, uma usando um arquivo de entrada espectral e a outra utilizando um arquivo relativo as alturas. Ainda, foram testados outros três métodos para comparação, sendo eles: a segmentação multiresolução do *software* eCognition; a detecção de locais máximos com janela fixa disponível no pacote rLiDAR; e a segmentação na nuvem de pontos com o aplicativo PointcloudITD.

A escolha desses métodos e *softwares* se baseou na busca dos métodos mais comuns utilizados para detecção de árvores e também no uso de métodos baseados em produtos diferentes, visto que os dados VANT permitem a obtenção de vários produtos. O resumo dos métodos testados está apresentado na TABELA 30. A descrição do procedimento para cada método será detalhada na sequência.

TABELA 30 - SUMÁRIO DOS MÉTODOS DE DETECÇÃO TESTADOS

Teste	Pacote/ferramenta	Arquivo de entrada	Método
1	TreeDetect	Banda NIR	Segmentação de bacias
2	TreeDetect	CHM	Segmentação de bacias
3	eCognition (multiresolution segmentation)	Ortomosaico	Segmentação e classificação
4	rLiDAR (FindTreesCHM)	CHM	Local máxima com janela fixa
5	PointcloudITD	Nuvem de pontos normalizada	Segmentação da nuvem de pontos

FONTE: A autora (2018).

A detecção foi, em todos os casos, executada para uma área de recorte compreendendo mais do que o talhão em si, portanto foram detectadas árvores além do seu limite. Para avaliar a capacidade de detecção, considerando somente a área efetivamente plantada, os resultados foram posteriormente recortados para um limite definido de área útil do talhão.

3.3.5.1 TreeDetect

A ferramenta TreeDetect foi aplicada de duas formas. Na primeira utilizou-se a resposta espectral da floresta, especificamente, com banda NIR do ortomosaico gerado com a câmera S110 NIR. Já no segundo teste, utilizou-se a resposta estrutural da vegetação com o uso do CHM gerado a partir da nuvem de pontos obtida com a câmera citada e normalizada (transformados para altura em relação ao solo) com o MDT LiDAR.

Uma vez que os dois arquivos compreendem dados com estruturas distintas, os parâmetros da ferramenta TreeDetect foram ajustados para cada caso e cada talhão, conforme a TABELA 31.

TABELA 31 - PARÂMETROS DA FERRAMENTA TREEDETECT UTILIZADOS PARA A DETECÇÃO DE ÁRVORES

Parâmetro	<i>Eucalyptus</i>		<i>Pinus 1</i>		<i>Pinus 2</i>	
Arquivo de entrada	Banda NIR	CHM	Banda NIR	CHM	Banda NIR	CHM
Tamanho da célula	0,5 m	0,3 m	0,5 m	0,5 m	0,5 m	0,3 m
Fator de conversão	-1	-1	-1	-1	-1	-1
Tamanho mínimo	3	3	3	3	2	2
Taxa de suavização	2	5	2	2	1	2

FONTE: A autora (2018).

3.3.5.2 eCognition

O eCognition é um dos mais conhecidos *softwares* para análise de imagens de alta resolução, e apresenta diversos algoritmos de segmentação e classificação, sendo que um dos mais populares é a segmentação multiresolução. Esse *software* já foi aplicado em outros estudos de detecção de árvores a partir de dados VANT com sucesso em plantios espaçados (KARYDAS et al., 2017) e, até mesmo, em classificação de algumas espécies em áreas temperadas (BROVKINA et al., 2018). A segmentação multiresolução parte da criação de objetos para cada pixel, que são unidos em várias iterações subsequentes com base num limite de homogeneidade

estabelecido, que é definido por critérios de resposta espectral e forma (TRIMBLE GERMANY GMBH, 2011). Nesse estudo utilizou-se a versão 8 do software.

Neste trabalho foi utilizada a segmentação multiresolução seguida por uma classificação básica. Na segmentação é possível a determinação de vários parâmetros, entre eles o peso de cada banda na segmentação, a escala dos objetos (valor abstrato que representa a máxima heterogeneidade permitida nos objetos), e a composição da homogeneidade, que é dada pelos parâmetros forma e compacidade (TRIMBLE GERMANY GMBH, 2011). Os valores de forma e compacidade variam de 0 até 0,9, e quanto maior valor for dado ao parâmetro de forma, menor será a importância da cor no processo de segmentação, e quanto maior for o valor de compacidade, mais compacta será a forma dos objetos definidos (TRIMBLE GERMANY GMBH, 2011).

Como entrada para a detecção foi utilizado o ortomosaico gerado com a câmera NIR, com três bandas, sendo elas Vermelha (1), Verde (2) e NIR (3). Os parâmetros de segmentação foram definidos por testes, em que se buscou segmentar as copas em objetos únicos, cujos os parâmetros aplicados estão apresentados na TABELA 32. Para os talhões de *Pinus* é maior a dificuldade para a segmentação das árvores de forma individualizada, devido à heterogeneidade das copas que se apresentavam em muitos casos bifurcadas ou quebradas.

TABELA 32 - PARÂMETROS DA SEGMENTAÇÃO MULTIRESOLUÇÃO

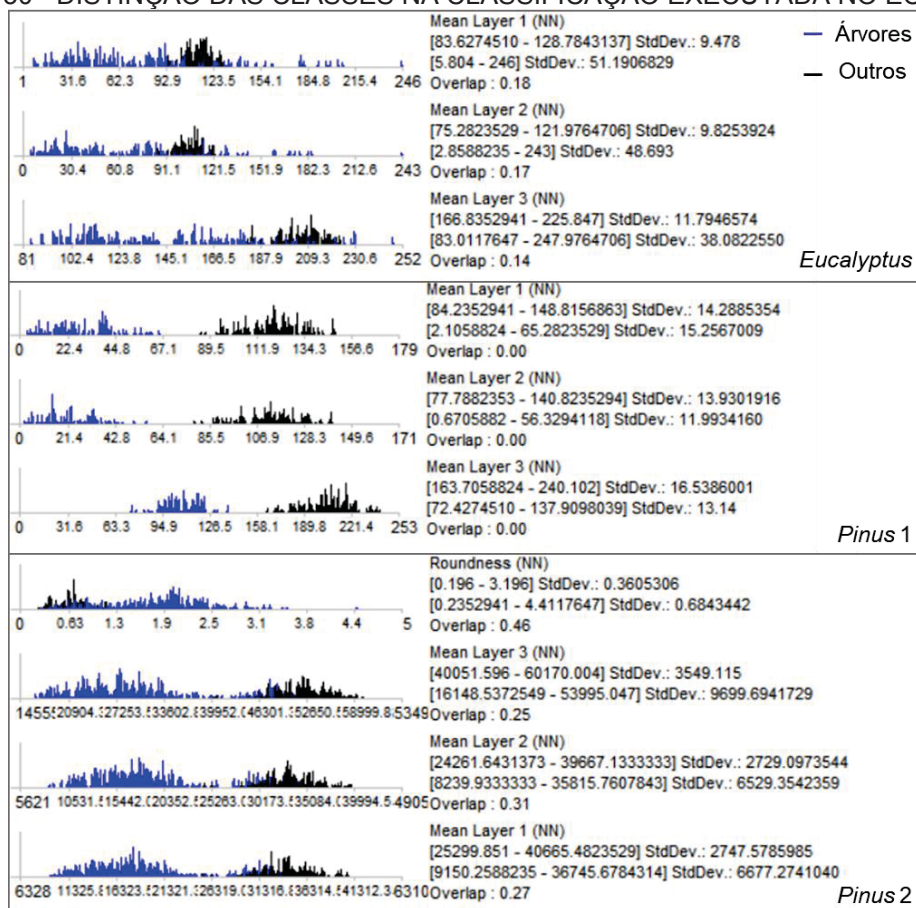
Talhão	Peso bandas	Escala	Forma	Compacidade
<i>Eucalyptus</i>	1,1,1	40	0,9	0,5
<i>Pinus</i> 1	1,1,1	60	0,9	0,7
<i>Pinus</i> 2	1,1,1	200	0,9	0,5

FONTE: A autora (2018).

Após a segmentação, foram selecionadas amostras de duas classes, “árvores” e “outros”, e os segmentos foram classificados com base no algoritmo do Vizinho Mais Próximo (NN - *Nearest Neighbor*). O algoritmo Vizinho Mais Próximo é um método de classificação de imagens que tem como princípio de funcionamento a determinação da classe de um objeto como a mesma classe da amostra mais próxima, de acordo com os parâmetros selecionados (SCHOWENGERDT, 2007). Para a classificação, parâmetros de resposta espectral e de formato foram testados, sendo selecionados os que apresentaram melhor diferenciação entre as duas classes. A diferenciação das classes foi dada pela média de cada uma das três bandas e pelo

parâmetro de circularidade no talhão *Pinus* 2, conforme FIGURA 30. Após a classificação, os polígonos relativos às árvores foram exportados, e de cada um destes foi extraído o ponto central para comparação com os demais métodos.

FIGURA 30 - DISTINÇÃO DAS CLASSES NA CLASSIFICAÇÃO EXECUTADA NO ECOGNITION



FONTE: A autora (2018).

3.3.5.3 rLiDAR

O pacote para linguagem R (R CORE TEAM, 2016) rLiDAR (SILVA et al., 2017a) foi desenvolvido com foco em aplicações florestais a partir de dados do LiDAR, como a detecção de árvores, delineamento de copas e alturas, a partir do uso de um CHM. A detecção das árvores é dada pela função *FindTreesCHM*, que utiliza uma função de locais máximos (*local maxima*) em uma janela de busca com raio definido e um determinado valor mínimo de altura (SILVA et al., 2017a). Outra função importante, no rLiDAR, é a *CHMsmoothing*, utilizada para suavizar o CHM e excluir pontos de locais máximas que se referem as variações das copas das árvores, como a presença de galhos. Para a suavização é utilizado um filtro que pode ser de média,

mediana, máximo ou Gaussiano, e uma determinada janela de busca. Os filtros irão substituir os valores da janela pelo respectivo valor do tipo de filtro, por exemplo, mantendo-se o valor médio.

Nesse caso, testou-se a detecção utilizando-se o CHM original (sem suavização), e com suavização de filtro de média com janelas 3 e 5. Na função de detecção em si, as janelas 3, 5 e 7 pixels foram utilizadas. Para cada talhão foram utilizados esses mesmos parâmetros de teste, encontrados em trabalhos similares com o rLiDAR (MOHAN et al., 2017). Conforme destacado anteriormente, o CHM foi gerado a partir do *software* Fusion e, para o caso do rLiDAR, optou-se por selecionar a resolução deste em 50 cm, pois em testes iniciais observou-se que resoluções mais altas criavam muitíssimos pontos espúrios. A detecção foi realizada com o parâmetros destacados e, para cada caso, escolheu-se a combinação de parâmetros que apresentou o melhor balanço entre erros de comissão e omissão em relação ao inventário de campo, e esses foram utilizados para as futuras análises, conforme a TABELA 33.

TABELA 33 - PARÂMETROS UTILIZADOS NO rLiDAR PARA DETECÇÃO DAS ÁRVORES.

Parâmetro	<i>Eucalyptus</i>	<i>Pinus 1</i>	<i>Pinus 2</i>
Arquivo de entrada	CHM 50 cm resolução	CHM 50 cm resolução	CHM 50 cm resolução
Suavização do CHM	Sem suavizar	Suavização média, 3x3	Sem suavizar
Janela de busca	5x5	3x3	3x3
Altura mínima	7 m	6 m	3 m

FONTE: A autora (2018).

3.3.5.4 PointcloudITD

O *software* PointcloudITD (denominado como ITD) foi desenvolvido em um projeto com objetivo de ampliar a aplicabilidade do algoritmo de detecção criado por Kathuria et al. (2016), originalmente desenvolvido para detecção de árvores coníferas em dados LiDAR de média densidade. O *software* PointcloudITD foi desenvolvido com o objetivo de ser aplicado para detecção de árvores, tanto coníferas como folhosas, e com base em nuvens de pontos aéreas (incluindo VANT e LiDAR) (BRYSON, 2017). A aplicação foi desenvolvida em C++ e Python e apresenta uma interface gráfica básica que permite a importação dos arquivos e otimização de parâmetros (BRYSON, 2017).

Esse algoritmo também é baseado na detecção de locais máximos, porém utilizando-se da nuvem de pontos normalizada e não de CHM, como a maioria das

outras técnicas, tendo como vantagem a detecção de árvores suprimidas ou parcialmente ocultas (em dados LiDAR), porém exige maior capacidade computacional (KATHURIA et al., 2016). Além da localização dos picos máximos, a ferramenta apresenta um segundo estágio em que os locais máximos são classificados como verdadeiros ou falsos, aplicando técnicas de aprendizado de máquina (BRYSON, 2017). Neste trabalho foi utilizado apenas o primeiro estágio, que compreende a detecção dos locais máximos em janelas de tamanho variável.

Utilizou-se a detecção de árvores pelo PointcloudITD por meio de: seleção da nuvem de pontos VANT normalizada (pelos MDT LiDAR), pela seleção dos raios mínimo e máximo de busca e pela execução da busca de locais máximos. Dessa forma, os únicos parâmetros que foram alterados para cada talhão foram os raios de busca, sendo que foi utilizado o valor máximo de 15 m para todos os casos, e os raios mínimos foram de 1,5 m para o talhão *Eucalyptus* e 1,2 m para ambos os talhões de *Pinus*. Assim como para os demais métodos, a seleção dos parâmetros foi feita pela execução da ferramenta com diversos parâmetros, até encontrar o valor que apresentou os resultados mais favoráveis em termos de detecção.

3.3.6 Análise da qualidade

A análise da qualidade da detecção dos algoritmos foi realizada em parcelas circulares simuladas em cada talhão. O tamanho das parcelas foi baseado no espaçamento de plantio de cada talhão e, portanto, a área útil ocupada por árvore para se dimensionar o tamanho da parcela com aproximadamente 60 árvores. Dessa forma, a área de cada parcela foi definida como aproximadamente 452 m² para os talhões *Eucalyptus* e *Pinus* 1, e 380 m² para o talhão *Pinus* 2, com raios de 12 m e 11 m, respectivamente. Objetivando-se amostrar aproximadamente 25% da área de cada talhão, foram sorteados 13, 17 e 18 parcelas para os talhões *Eucalyptus*, *Pinus* 1 e *Pinus* 2, respectivamente.

A localização das parcelas foi feita pelo sorteio aleatório do ponto central com posterior materialização da área a partir da definição do tamanho do raio. Em cada parcela foram então identificadas as árvores inventariadas em campo e delimitadas suas copas utilizando-se os ortomosaicos disponíveis. No caso de árvores não visíveis (mortas, quebradas, rebrotas ou outras), essas não foram contabilizadas. No caso de árvores próximas à borda, determinou-se que essas seriam consideradas

pertencentes à parcela quando mais de 50% de suas copas estivessem incluídas em sua área. Árvores bifurcadas abaixo do dap com possibilidade de identificação de duas copas foram delimitadas como ocorrências distintas.

Dada a delimitação das copas, cada árvore detectada dentro das parcelas foi avaliada e considerada como: verdadeira positiva (VP), quando o ponto detectado encontrava-se na área de copa delimitada; falsa positiva (FP), quando o ponto detectado encontrava-se fora das copas delimitadas ou quando mais de um ponto era detectado na mesma copa – nesse caso o ponto mais central era considerado VP e os demais FP; ou falsa negativa (FN), quando não era encontrado nenhum ponto de detecção em uma copa delimitada com base nos dados de campo. A partir do total de VP, FP e FN foram calculadas as taxas de rejeição (recall - r), precisão (p) e F-score (F) para cada parcela, com base no trabalho de Li et al. (2012), e nas equações 1, 2 e 3 a seguir. Segundo Li et al. (2012), o valor de r refere-se a taxa de detecção, o valor de p ao quão correta é a detecção, e o valor de F é a exatidão geral com base nos valores de comissão e omissão. Os três parâmetros variam de 0-1, e quando mais próximo de 1 melhor será o resultado.

$$r = \frac{VP}{VP + FN} \quad (1)$$

$$p = \frac{VP}{VP + FP} \quad (2)$$

$$F = 2 \cdot \frac{r \cdot p}{r + p} \quad (3)$$

Em que: r = rejeição; p = precisão; F = F-score; VP = verdadeiro positivo; FP = falso positivo; e FN = falso negativo.

Além dos parâmetros r , p e F , o resultado da detecção de cada método foi também avaliado pelo teste Qui-quadrado, considerando-se que a frequência esperada era o valor real de árvores na parcela (as árvores visíveis observadas em campo) e o valor observado era o total de árvores detectadas (VP e FP), aplicando-se a Equação 4.

$$\chi_k^2 = \sum_{i=1}^m \sum_{j=1}^n \frac{(O_{ij} - E_{ij})^2}{E_{ij}} \quad (4)$$

Em que: O_{ij} = número observado de árvores; e E_{ij} = número esperado de árvores.

O valor de Qui-quadrado calculado para cada método foi confrontado com o valor tabelado do teste, considerando-se a probabilidade de 95% (mais rigorosa que 99% para aderência) para as seguintes hipóteses:

- Hipótese nula (H_0): o número de árvores detectadas não é diferente do número de árvores observado em campo;
- Hipótese alternativa (H_1): o número de árvores detectadas é diferente do número de árvores observado em campo;

Ainda, o total de árvores observado em cada talhão foi confrontado com o total de árvores detectada em cada método, de forma que foi possível avaliar a qualidade geral da detecção de cada método.

3.4 RESULTADOS

O total de árvores detectadas no talhão *Eucalyptus*, para as 13 parcelas simuladas e para o talhão inteiro, com os diferentes métodos está apresentado na TABELA 34. Observa-se que a média de árvores detectadas nas parcelas não difere significativamente dos dados de campo em todos os métodos. Considerando-se as parcelas, o método que apresentou o resultado mais próximo foi o do rLiDAR, com uma diferença total de 9 árvores (1,5%), enquanto que quando considerado o talhão como um todo, o melhor resultado foi obtido com o eCognition, que apresentou diferença de apenas 57 árvores (2,7%).

TABELA 34 - RESULTADOS DA DETECÇÃO DE ÁRVORES PELOS DIFERENTES MÉTODOS NO TALHÃO *EUCALYPTUS*

Parc.	Censo	TreeDetect NIR			TreeDetect CHM			eCognition			rLiDAR			ITD		
		N	Dif.	%	N	Dif.	%	N	Dif.	%	N	Dif.	%	N	Dif.	%
1	45	43	2	4,4	56	-11	-24,4	40	5	11,1	51	-6	-13,3	45	0	0,0
2	42	39	3	7,1	56	-14	-33,3	41	1	2,4	53	-11	-26,2	48	-6	-14,3
3	42	45	-3	-7,1	48	-6	-14,3	39	3	7,1	46	-4	-9,5	37	5	11,9
4	41	39	2	4,9	42	-1	-2,4	43	-2	-4,9	42	-1	-2,4	36	5	12,2
5	43	42	1	2,3	39	4	9,3	46	-3	-7,0	36	7	16,3	30	13	30,2
6	42	39	3	7,1	48	-6	-14,3	43	-1	-2,4	45	-3	-7,1	41	1	2,4
7	44	43	1	2,3	44	0	0,0	38	6	13,6	44	0	0,0	39	5	11,4
8	58	55	3	5,2	49	9	15,5	50	8	13,8	44	14	24,1	42	16	27,6
9	48	47	1	2,1	60	-12	-25,0	47	1	2,1	53	-5	-10,4	45	3	6,3
10	43	42	1	2,3	47	-4	-9,3	40	3	7,0	41	2	4,7	39	4	9,3
11	45	43	2	4,4	44	1	2,2	40	5	11,1	45	0	0,0	38	7	15,6
12	46	47	-1	-2,2	42	4	8,7	42	4	8,7	38	8	17,4	35	11	23,9
13	51	47	4	7,8	48	3	5,9	53	-2	-3,9	43	8	15,7	37	14	27,5
Σ parc.	590	571 ^{ns}	19	3,2	623 ^{ns}	-33	-5,6	562 ^{ns}	28	4,7	581 ^{ns}	9	1,5	512 ^{ns}	78	13,2
Talhão	2.136	2.053	83	3,9	2.322	-186	-8,7	2.079	57	2,7	2.066	70	3,3	1.878	258	12,1

Em que: N: número de árvores; Dif: diferença entre censo e detecção; %: diferença percentual; Parc: parcela; ns: não significativo pelo teste Qui-quadrado a 95% de probabilidade.

FONTE: A autora (2018).

Quando utilizada a ferramenta TreeDetect, os resultados foram melhores com o uso da banda NIR em comparação com o CHM, sendo que o primeiro atingiu erro de 3,9% no talhão como um todo e o segundo -8,7%. O uso do CHM na ferramenta TreeDetect foi o método que mais superestimou o número de árvores, enquanto que o ITD foi o que mais subestimou.

A análise da qualidade da detecção nas parcelas está apresentada na TABELA 35, para os dois métodos com a ferramenta TreeDetect, e na TABELA 36 para os demais métodos.

TABELA 35 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM A FERRAMENTA TREEDTECT NO TALHÃO *EUCALYPTUS*

Parcela	Censo	TreeDetect NIR						TreeDetect CHM					
		VP	FP	FN	r	p	F	VP	FP	FN	r	p	F
1	45	43	0	2	0,96	1,00	0,98	37	19	8	0,82	0,66	0,73
2	42	39	0	3	0,93	1,00	0,96	36	20	6	0,86	0,64	0,73
3	42	42	3	0	1,00	0,93	0,97	35	13	7	0,83	0,73	0,78
4	41	39	0	2	0,95	1,00	0,98	28	14	13	0,68	0,67	0,67
5	43	41	1	2	0,95	0,98	0,96	30	9	13	0,70	0,77	0,73
6	42	38	1	4	0,90	0,97	0,94	30	18	12	0,71	0,63	0,67
7	44	41	2	3	0,93	0,95	0,94	32	12	12	0,73	0,73	0,73
8	58	55	0	3	0,95	1,00	0,97	41	8	17	0,71	0,84	0,77
9	48	46	1	2	0,96	0,98	0,97	40	20	8	0,83	0,67	0,74
10	43	42	0	1	0,98	1,00	0,99	34	13	9	0,79	0,72	0,76
11	45	43	0	2	0,96	1,00	0,98	32	12	13	0,71	0,73	0,72
12	46	41	6	5	0,89	0,87	0,88	36	6	10	0,78	0,86	0,82
13	51	46	1	5	0,90	0,98	0,94	35	13	16	0,69	0,73	0,71
Total	590	556	15	34	0,94	0,97	0,96	446	177	144	0,76	0,72	0,74

Em que: VP: verdadeiro positivo; FP: falso positivo; FN: falso negativo; r: rejeição; p: precisão; F: F-score.

FONTE: A autora (2018).

TABELA 36 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM OUTROS MÉTODOS PARA O TALHÃO *EUCALYPTUS*

Parc.	eCognition						rLIDAR						ITD					
	VP	FP	FN	r	p	F	VP	FP	FN	r	p	F	VP	FP	FN	r	p	F
1	36	4	9	0,80	0,90	0,85	33	18	12	0,73	0,65	0,69	32	13	13	0,71	0,71	0,71
2	36	5	6	0,86	0,88	0,87	35	18	7	0,83	0,66	0,74	30	18	12	0,71	0,63	0,67
3	35	4	7	0,83	0,90	0,86	30	16	12	0,71	0,65	0,68	24	13	18	0,57	0,65	0,61
4	32	11	9	0,78	0,74	0,76	24	18	17	0,59	0,57	0,58	26	10	15	0,63	0,72	0,68
5	37	9	6	0,86	0,80	0,83	30	6	13	0,70	0,83	0,76	29	1	14	0,67	0,97	0,79
6	35	8	7	0,83	0,81	0,82	30	15	12	0,71	0,67	0,69	28	13	14	0,67	0,68	0,67
7	36	2	8	0,82	0,95	0,88	32	12	12	0,73	0,73	0,73	31	8	13	0,70	0,79	0,75
8	44	6	14	0,76	0,88	0,81	38	6	20	0,66	0,86	0,75	38	4	20	0,66	0,90	0,76
9	39	8	9	0,81	0,83	0,82	37	16	11	0,77	0,70	0,73	35	10	13	0,73	0,78	0,75
10	36	4	7	0,84	0,90	0,87	30	11	13	0,70	0,73	0,71	31	8	12	0,72	0,79	0,76
11	32	8	13	0,71	0,80	0,75	31	14	14	0,69	0,69	0,69	25	13	20	0,56	0,66	0,60
12	36	6	10	0,78	0,86	0,82	34	4	12	0,74	0,89	0,81	33	2	13	0,72	0,94	0,81
13	45	8	6	0,88	0,85	0,87	30	13	21	0,59	0,70	0,64	31	6	20	0,61	0,84	0,70
Total	479	83	111	0,81	0,85	0,83	414	167	176	0,70	0,71	0,71	393	119	197	0,67	0,77	0,71

Em que: VP: verdadeiro positivo; FP: falso positivo; FN: falso negativo; r: rejeição; p: precisão; F: F-score; Parc: parcela.

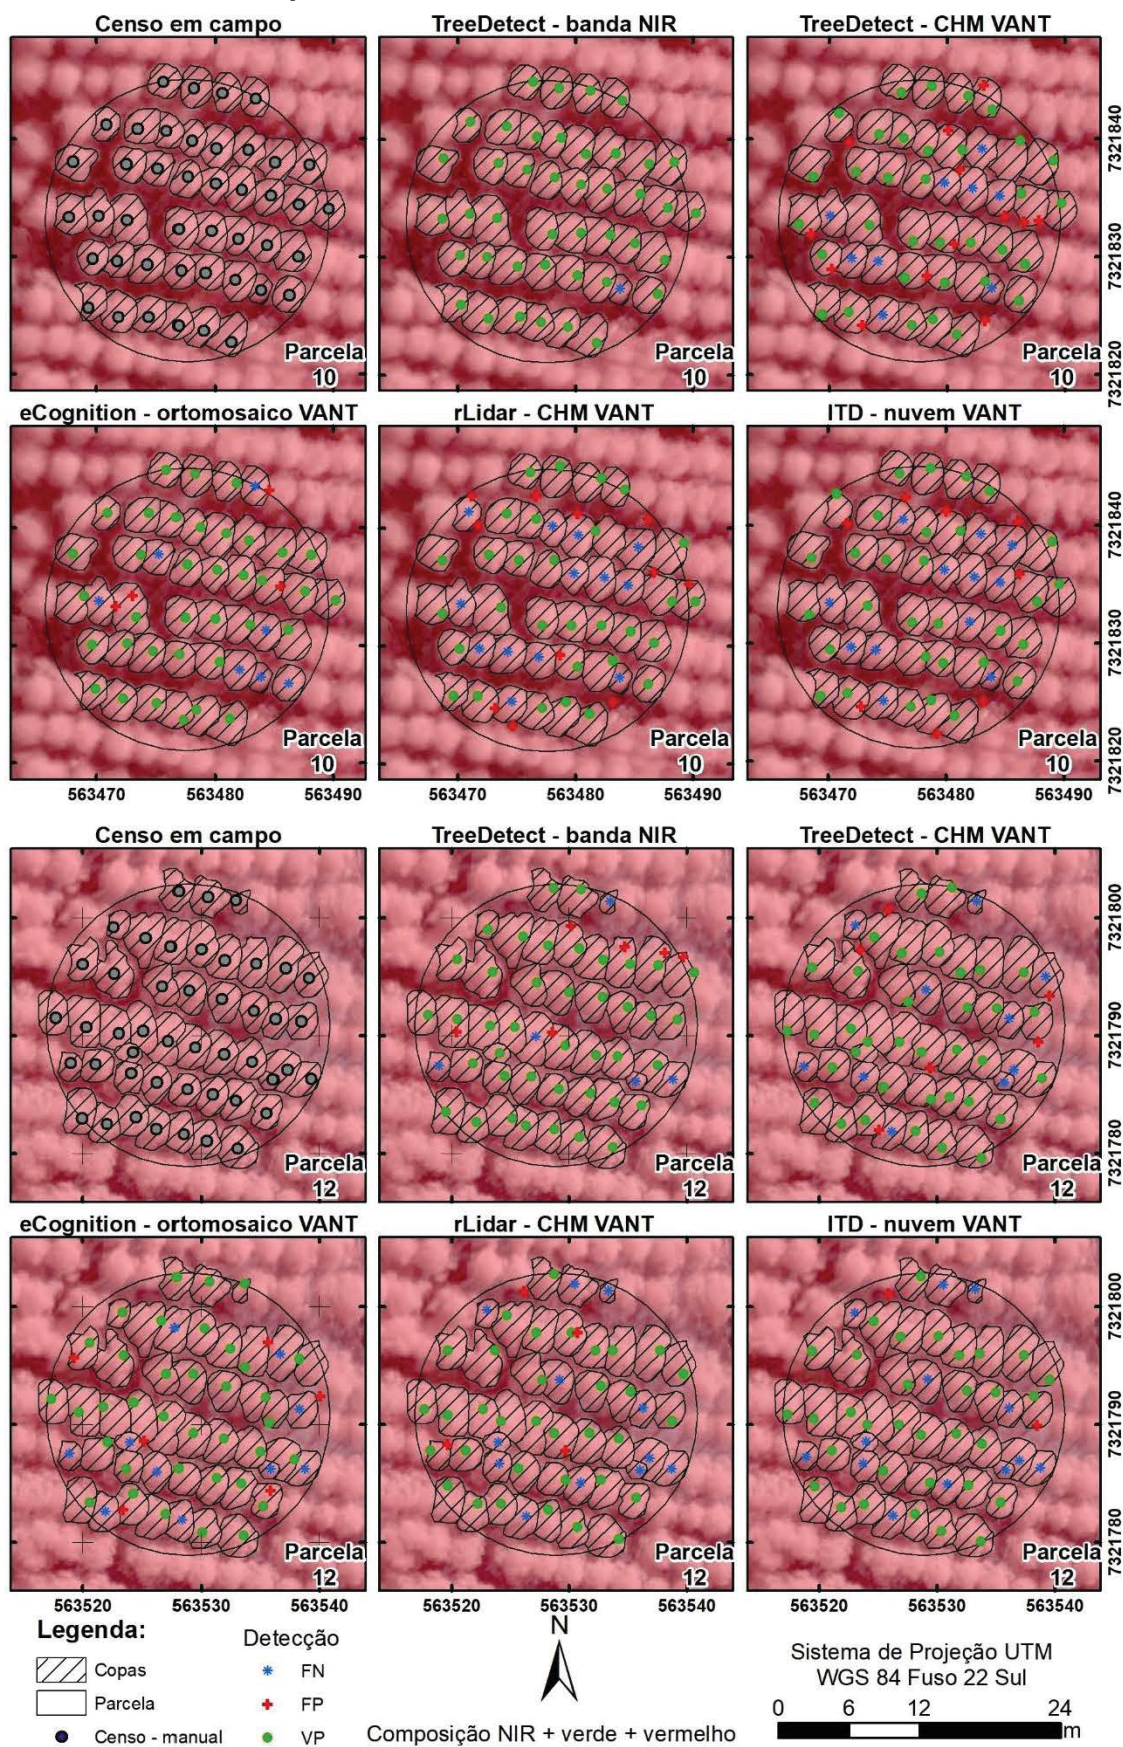
FONTE: A autora (2018).

O melhor valor de F-score para cada parcela foi destacado em negrito, e observa-se que em todos os casos esse valor foi obtido com a ferramenta TreeDetect

utilizando a banda NIR. O F-score geral da ferramenta TreeDetect com a banda NIR foi de 0,96, seguido pelas detecções com eCognition (F-score 0,83), TreeDetect com o CHM (F-score 0,74), e rLiDAR e ITD ambos com F-score 0,71. O uso da banda NIR e ferramenta TreeDetect também se destaca pelos altos valores de r e principalmente de p , que atingiu valor máximo (1) em 6 das 13 parcelas.

O resultado da detecção com os métodos aplicados está exemplificado graficamente na FIGURA 31 para as parcelas 10 e 12, que apresentaram, respectivamente o maior e menor F-score com o uso da banda NIR e ferramenta TreeDetect. Na parcela 10 observa-se que a detecção foi praticamente perfeita com a ferramenta TreeDetect e banda NIR, enquanto que os demais métodos tenderam a não identificar algumas árvores. Os maiores números de FP foram observados nos métodos baseados em CHM e na nuvem de pontos.

Na parcela 12 foi observada maior ocorrência de FN, principalmente de árvores com copas menores, algumas não detectadas na maioria dos métodos. Erros do tipo FP foram observados principalmente em copas maiores, pela identificação de dois pontos na mesma copa.

FIGURA 31 - DETECÇÃO DE ÁRVORES NAS PARCELAS DO TALHÃO *EUCALYPTUS*

Para o talhão *Pinus* 1 os resultados de detecção estão apresentados na TABELA 37. Nesse talhão os resultados de detecção foram inferiores ao talhão *Eucalyptus*, com erros variando entre -2,3% e 30,6% para o talhão total. O método que mais se aproximou do número de árvores no talhão como um todo foi o ITD com -2,3% de diferença. A ferramenta TreeDetect com uso da banda NIR ficou em segunda colocação para o talhão, e em primeira para as parcelas, com erro de 4,1% para ambos. Ambas as aplicações com a ferramenta TreeDetect, assim como o algoritmo ITD apresentaram média de árvores detectadas que não diferem significativamente dos valores observados em campo. O uso do eCognition e do algoritmo do rLiDAR apresentaram diferença significativa pelo teste Qui-quadrado comparados com os dados de campo. A ferramenta TreeDetect com uso da banda NIR e o aplicativo ITD apresentaram superestimava do número real de árvores, enquanto que o eCognition e rLiDAR apresentaram subestimativa na maior parte dos casos.

TABELA 37 - RESULTADOS DA DETECÇÃO DE ÁRVORES PELOS DIFERENTES MÉTODOS NO TALHÃO *PINUS* 1

Parcelas Censo		TreeDetect NIR			TreeDetect CHM			eCognition			rLiDAR			ITD		
		N	Dif	%	N	Dif	%	N	Dif	%	N	Dif	%	N	Dif	%
1	44	51	-7	-15,9	39	5	11,4	41	3	6,8	32	12	27,3	43	1	2,3
2	48	56	-8	-16,7	42	6	12,5	46	2	4,2	33	15	31,3	52	-4	-8,3
3	41	47	-6	-14,6	38	3	7,3	41	0	0,0	23	18	43,9	34	7	17,1
4	37	46	-9	-24,3	42	-5	-13,5	32	5	13,5	26	11	29,7	42	-5	-13,5
5	43	52	-9	-20,9	43	0	0,0	38	5	11,6	36	7	16,3	47	-4	-9,3
6	48	51	-3	-6,3	41	7	14,6	40	8	16,7	31	17	35,4	52	-4	-8,3
7	44	48	-4	-9,1	45	-1	-2,3	34	10	22,7	31	13	29,5	43	1	2,3
8	51	46	5	9,8	45	6	11,8	35	16	31,4	40	11	21,6	57	-6	-11,8
9	39	48	-9	-23,1	38	1	2,6	44	-5	-12,8	33	6	15,4	44	-5	-12,8
10	50	54	-4	-8,0	50	0	0,0	24	26	52,0	41	9	18,0	50	0	0,0
11	45	44	1	2,2	39	6	13,3	27	18	40,0	32	13	28,9	46	-1	-2,2
12	46	53	-7	-15,2	43	3	6,5	40	6	13,0	32	14	30,4	49	-3	-6,5
13	43	52	-9	-20,9	41	2	4,7	21	22	51,2	41	2	4,7	45	-2	-4,7
14	37	48	-11	-29,7	28	9	24,3	33	4	10,8	21	16	43,2	27	10	27,0
15	31	38	-7	-22,6	39	-8	-25,8	35	-4	-12,9	24	7	22,6	37	-6	-19,4
16	44	57	-13	-29,5	49	-5	-11,4	33	11	25,0	40	4	9,1	55	-11	-25,0
17	39	51	-12	-30,8	38	1	2,6	40	-1	-2,6	31	8	20,5	45	-6	-15,4
Σ par.	730	842 ^{ns}	-112	-15,3	700 ^{ns}	30	4,1	604*	126	17,3	547*	183	25,1	768 ^{ns}	-38	-5,2
Talhão	2.797	3.231	-434	-15,5	2.681	116	4,1	2.425	372	13,3	1.942	855	30,6	2.862	-65	-2,3

Em que: N: número de árvores; Dif: diferença entre censo e detecção; %: diferença percentual; Parc: parcela; * e ns: respectivamente, significativo e não significativo pelo teste Qui-quadrado a 95% de probabilidade.

FONTE: A autora (2018).

A análise de qualidade das detecções está apresentada nas TABELA 38 e TABELA 39, para a ferramenta TreeDetect e para os demais métodos, respectivamente. Considerando os valores de F-score, os melhores resultados foram obtidos pela ferramenta TreeDetect utilizando a banda NIR na maioria das parcelas, cujo resultado geral foi de 0,80, seguido por 0,74 para a TreeDetect com o CHM, rLiDAR e ITD, e 0,71 para o eCognition.

TABELA 38 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM A FERRAMENTA TREEDETECT NO TALHÃO *PINUS 1*

Parcela	Censo	TreeDetect NIR						TreeDetect CHM					
		VP	FP	FN	r	p	F	VP	FP	FN	r	p	F
1	44	37	14	7	0,84	0,73	0,78	30	9	13	0,70	0,77	0,73
2	48	41	15	7	0,85	0,73	0,79	31	11	17	0,65	0,74	0,69
3	41	34	13	7	0,83	0,72	0,77	31	7	10	0,76	0,82	0,78
4	37	35	11	2	0,95	0,76	0,84	30	12	7	0,81	0,71	0,76
5	43	38	14	5	0,88	0,73	0,80	35	8	8	0,81	0,81	0,81
6	48	39	12	9	0,81	0,76	0,79	30	11	18	0,63	0,73	0,67
7	44	35	13	9	0,80	0,73	0,76	31	14	13	0,70	0,69	0,70
8	51	39	7	12	0,76	0,85	0,80	34	11	18	0,65	0,76	0,70
9	39	36	12	3	0,92	0,75	0,83	29	9	10	0,74	0,76	0,75
10	50	43	11	7	0,86	0,80	0,83	42	8	8	0,84	0,84	0,84
11	45	37	7	8	0,82	0,84	0,83	30	9	15	0,67	0,77	0,71
12	46	39	14	7	0,85	0,74	0,79	34	9	12	0,74	0,79	0,76
13	43	36	16	7	0,84	0,69	0,76	31	10	12	0,72	0,76	0,74
14	37	33	15	4	0,89	0,69	0,78	23	5	14	0,62	0,82	0,71
15	31	29	9	2	0,94	0,76	0,84	28	11	3	0,90	0,72	0,80
16	44	40	17	4	0,91	0,70	0,79	32	17	12	0,73	0,65	0,69
17	39	34	17	5	0,87	0,67	0,76	31	7	8	0,79	0,82	0,81
Total	730	625	217	105	0,86	0,74	0,80	532	168	198	0,73	0,76	0,74

Em que: VP: verdadeiro positivo; FP: falso positivo; FN: falso negativo; r: rejeição; p: precisão; F: F-score.

FONTE: A autora (2018).

TABELA 39 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM OUTROS MÉTODOS PARA O TALHÃO *PINUS 1*


Parc.	eCognition						rLiDAR						ITD					
	VP	FP	FN	r	p	F	VP	FP	FN	r	p	F	VP	FP	FN	r	p	F
1	26	15	18	0,59	0,63	0,61	30	2	14	0,68	0,94	0,79	32	11	12	0,73	0,74	0,74
2	34	12	14	0,71	0,74	0,72	27	6	21	0,56	0,82	0,67	35	17	13	0,73	0,67	0,70
3	29	12	12	0,71	0,71	0,71	22	1	19	0,54	0,96	0,69	27	7	14	0,66	0,79	0,72
4	26	6	11	0,70	0,81	0,75	24	2	13	0,65	0,92	0,76	29	13	8	0,78	0,69	0,73
5	31	7	12	0,72	0,82	0,77	31	5	12	0,72	0,86	0,78	36	11	7	0,84	0,77	0,80
6	33	7	15	0,69	0,83	0,75	24	7	24	0,5	0,77	0,61	33	19	15	0,69	0,63	0,66
7	26	8	18	0,59	0,76	0,67	28	3	16	0,64	0,9	0,75	32	11	12	0,73	0,74	0,74
8	30	5	21	0,59	0,86	0,70	34	6	17	0,67	0,85	0,75	40	17	11	0,78	0,70	0,74
9	31	13	8	0,79	0,70	0,75	28	5	11	0,72	0,85	0,78	31	13	8	0,79	0,70	0,75
10	21	3	29	0,42	0,88	0,57	37	4	13	0,74	0,9	0,81	41	9	9	0,82	0,82	0,82
11	25	2	20	0,56	0,93	0,69	26	6	19	0,58	0,81	0,68	34	12	11	0,76	0,74	0,75
12	30	10	16	0,65	0,75	0,70	31	1	15	0,67	0,97	0,79	35	14	11	0,76	0,71	0,74
13	21	0	22	0,49	1,00	0,66	30	11	13	0,7	0,73	0,71	32	13	11	0,74	0,71	0,73
14	26	7	11	0,70	0,79	0,74	21	0	16	0,57	1,00	0,72	25	2	12	0,68	0,93	0,78
15	27	8	4	0,87	0,77	0,82	22	2	9	0,71	0,92	0,80	25	12	6	0,81	0,68	0,74
16	27	6	17	0,61	0,82	0,70	32	8	12	0,73	0,8	0,76	36	19	8	0,82	0,65	0,73
17	30	10	9	0,77	0,75	0,76	28	3	11	0,72	0,9	0,80	33	12	6	0,85	0,73	0,79
Total	473	131	257	0,65	0,78	0,71	475	72	255	0,65	0,87	0,74	556	212	174	0,76	0,72	0,74

Em que: VP: verdadeiro positivo; FP: falso positivo; FN: falso negativo; r: rejeição; p: precisão; F: F-score; Parc: parcela.

FONTE: A autora (2018).

Na FIGURA 32 estão apresentados os resultados da detecção com os métodos testados para as parcelas 4 e 7, que apresentaram o melhor e pior resultados com a ferramenta TreeDetect e banda NIR.

FIGURA 32 - DETECÇÃO DE ÁRVORES NAS PARCELAS DO TALHÃO *PINUS* 1



FONTE: A autora (2018).

Em ambos os casos, a maior parte dos erros do tipo FN é observada em árvores com copas menores, principalmente na parcela 7, que apresenta várias árvores menores. Já erros do tipo FP são comuns em copas maiores.

Os resultados para o talhão *Pinus 2*, referentes ao total de árvores detectadas, estão apresentados na TABELA 40. Nesse talhão, o resultado mais próximo aos observados nas parcelas e no talhão foi obtido com uso do CHM na ferramenta TreeDetect com -4,2% e -4,7 de diferença, respectivamente. A maioria dos métodos foi capaz de detectar as árvores das parcelas sem diferença significativa em relação aos dados de campo, com exceção do eCognition e do algoritmo ITD, que apresentam diferença estatisticamente significativa e que subestimaram o número de árvores nas parcelas e no talhão como um todo. Os métodos com o rLiDAR e com o CHM aplicado na ferramenta TreeDetect superestimaram o número de árvores na maioria das parcelas.

TABELA 40 - RESULTADOS DA DETECÇÃO DE ÁRVORES PELOS DIFERENTES MÉTODOS NO TALHÃO *PINUS 2*

Parcelas Censo		TreeDetect NIR			TreeDetect CHM			eCognition			rLiDAR			ITD		
		N	Dif	%	N	Dif	%	N	Dif	%	N	Dif	%	N	Dif	%
1	53	53	0	0,0	57	-4	-7,5	51	2	3,8	57	-4	-7,5	48	5	9,4
2	60	55	5	8,3	65	-5	-8,3	53	7	11,7	67	-7	-11,7	48	12	20,0
3	59	54	5	8,5	60	-1	-1,7	45	14	23,7	63	-4	-6,8	50	9	15,3
4	61	59	2	3,3	65	-4	-6,6	46	15	24,6	63	-2	-3,3	56	5	8,2
5	64	60	4	6,3	66	-2	-3,1	48	16	25,0	74	-10	-15,6	55	9	14,1
6	65	54	11	16,9	60	5	7,7	52	13	20,0	66	-1	-1,5	45	20	30,8
7	61	57	4	6,6	62	-1	-1,6	51	10	16,4	64	-3	-4,9	53	8	13,1
8	65	69	-4	-6,2	69	-4	-6,2	54	11	16,9	74	-9	-13,8	58	7	10,8
9	64	59	5	7,8	65	-1	-1,6	53	11	17,2	71	-7	-10,9	49	15	23,4
10	60	61	-1	-1,7	62	-2	-3,3	50	10	16,7	63	-3	-5,0	48	12	20,0
11	57	60	-3	-5,3	62	-5	-8,8	53	4	7,0	62	-5	-8,8	52	5	8,8
12	64	56	8	12,5	65	-1	-1,6	54	10	15,6	79	-15	-23,4	47	17	26,6
13	51	48	3	5,9	54	-3	-5,9	42	9	17,6	58	-7	-13,7	45	6	11,8
14	61	57	4	6,6	64	-3	-4,9	46	15	24,6	73	-12	-19,7	53	8	13,1
15	61	57	4	6,6	65	-4	-6,6	31	30	49,2	70	-9	-14,8	49	12	19,7
16	64	61	3	4,7	69	-5	-7,8	49	15	23,4	73	-9	-14,1	54	10	15,6
17	56	56	0	0,0	60	-4	-7,1	48	8	14,3	71	-15	-26,8	53	3	5,4
18	61	60	1	1,6	63	-2	-3,3	52	9	14,8	69	-8	-13,1	50	11	18,0
Σ	1.087	1.036 ^{ns}	51	4,7	1.133 ^{ns}	-46	-4,2	878*	209	19,2	1.217 ^{ns}	-130	-12,0	913*	174	16,0
Talhão	4.211	3.962	249	5,9	4.411	-200	-4,7	3.256	955	22,7	4.573	-362	-8,6	3.306	905	21,5

Em que: N: número de árvores; Dif: diferença entre censo e detecção; %: diferença percentual; * e ns: respectivamente, significativo e não significativo pelo teste Qui-quadrado a 95% de probabilidade.

FONTE: A autora (2018).

A qualidade das detecções estão apresentadas nas TABELA 41, para a ferramenta TreeDetect, e TABELA 42 para os demais métodos. Nesse talhão, o uso da ferramenta TreeDetect com a banda NIR e o algoritmo ITD apresentaram os melhores resultados de F-score, em 9 parcelas cada (considerando que resultados iguais foram somados para ambas). O uso da TreeDetect com o CHM também se mostrou o melhor em relação ao F-score em um grande número de parcelas.

TABELA 41 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM A FERRAMENTA TREEDETECT NO TALHÃO *PINUS 2*

Parcela	Censo	TreeDetect NIR						TreeDetect CHM					
		VP	FP	FN	r	p	F	VP	FP	FN	r	p	F
1	53	44	9	9	0,83	0,83	0,83	47	10	6	0,89	0,82	0,85
2	60	53	2	7	0,88	0,96	0,92	55	10	5	0,92	0,85	0,88
3	59	47	7	12	0,80	0,87	0,83	52	8	7	0,88	0,87	0,87
4	61	55	4	6	0,90	0,93	0,92	57	8	4	0,93	0,88	0,90
5	64	56	4	8	0,88	0,93	0,90	57	9	7	0,89	0,86	0,88
6	65	52	2	13	0,80	0,96	0,87	51	9	14	0,78	0,85	0,82
7	61	51	6	10	0,84	0,89	0,86	58	4	3	0,95	0,94	0,94
8	65	60	9	5	0,92	0,87	0,90	63	6	2	0,97	0,91	0,94
9	64	56	3	8	0,88	0,95	0,91	53	12	11	0,83	0,82	0,82
10	60	53	8	7	0,88	0,87	0,88	52	10	8	0,87	0,84	0,85
11	57	52	8	5	0,91	0,87	0,89	52	10	5	0,91	0,84	0,87
12	64	53	3	11	0,83	0,95	0,88	57	8	7	0,89	0,88	0,88
13	51	44	4	8	0,85	0,92	0,88	44	10	7	0,86	0,81	0,84
14	61	54	3	8	0,87	0,95	0,91	57	7	4	0,93	0,89	0,91
15	61	52	5	9	0,85	0,91	0,88	54	11	7	0,89	0,83	0,86
16	64	58	3	6	0,91	0,95	0,93	62	7	2	0,97	0,90	0,93
17	56	48	8	8	0,86	0,86	0,86	53	7	3	0,95	0,88	0,91
18	61	56	4	5	0,92	0,93	0,93	55	8	6	0,90	0,87	0,89
Total	1087	944	92	145	0,87	0,91	0,89	979	154	108	0,90	0,86	0,88

Em que: VP: verdadeiro positivo; FP: falso positivo; FN: falso negativo; r: rejeito; p: precisão; F: F-score.

FONTE: A autora (2018).

TABELA 42 - ANÁLISE DE QUALIDADE DA DETECÇÃO DE ÁRVORES COM OUTROS MÉTODOS PARA O TALHÃO *PINUS 2*

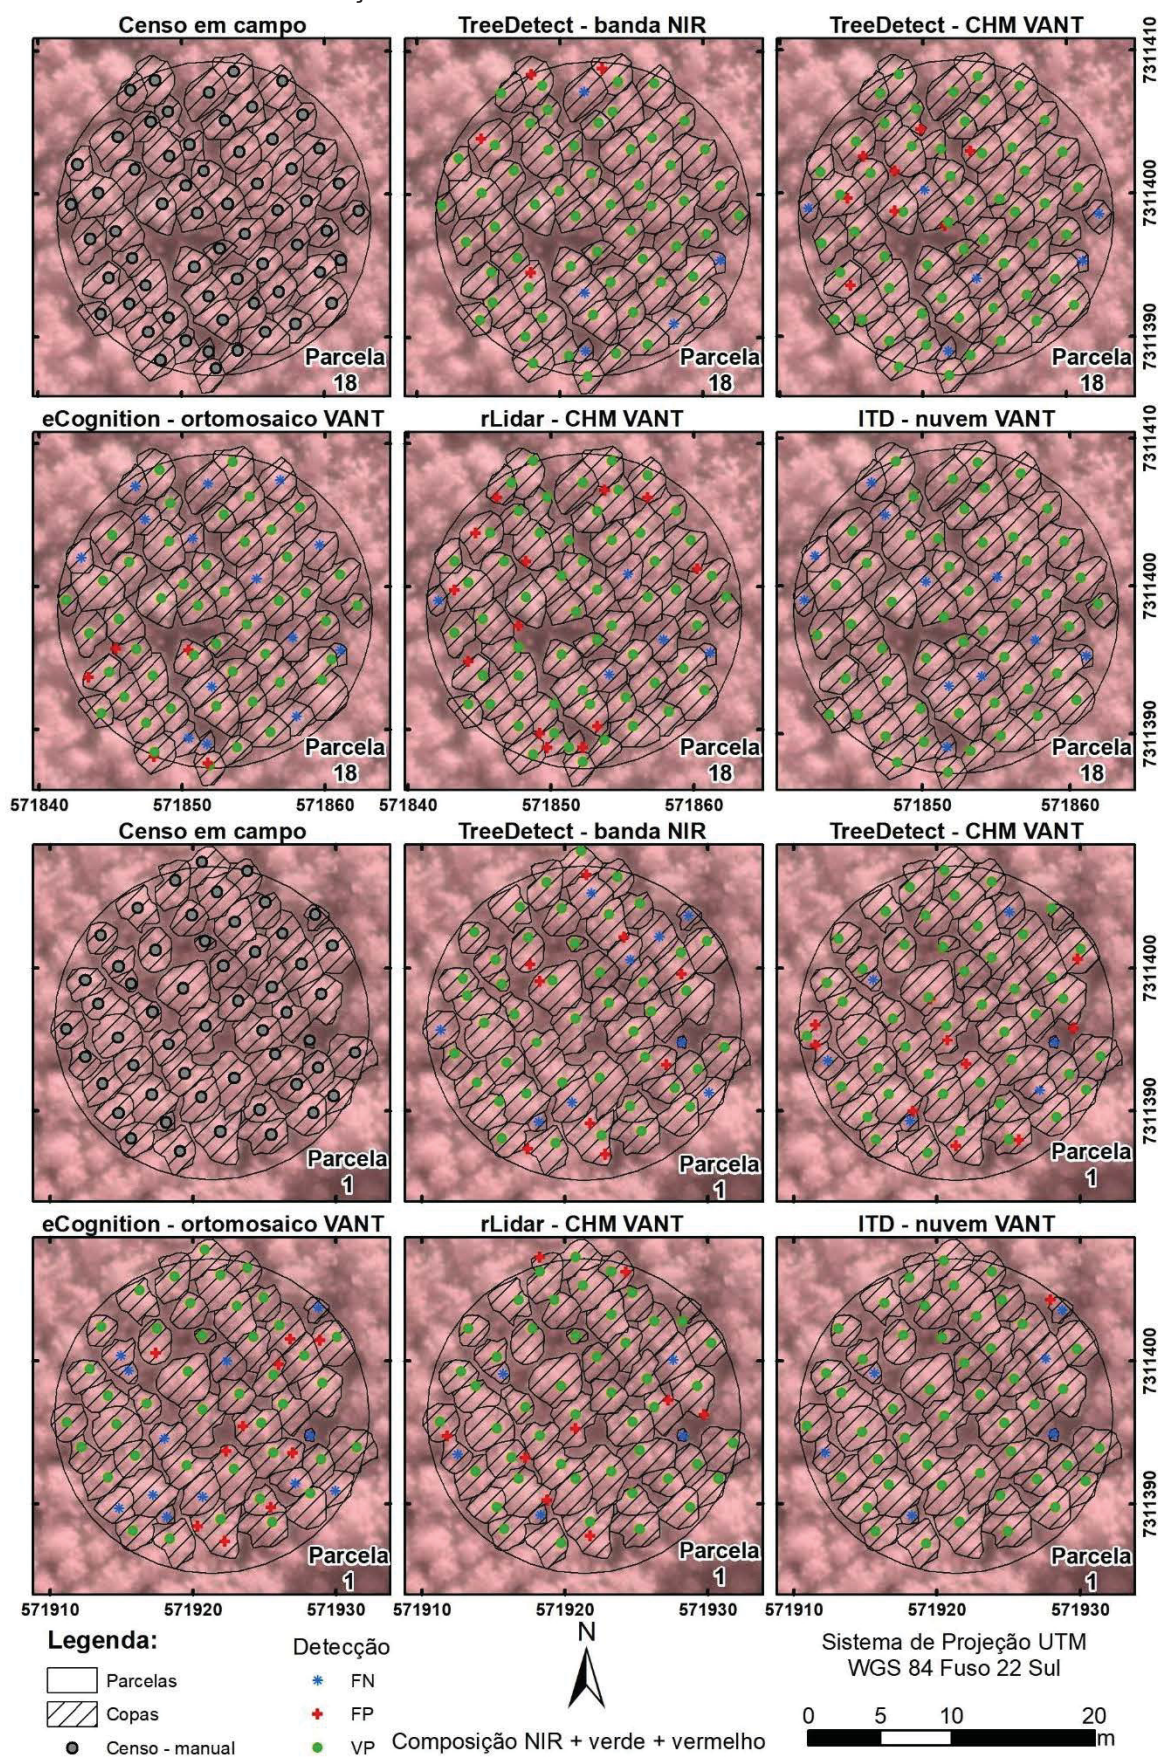
Parc.	eCognition						rLiDAR						ITD					
	VP	FP	FN	r	p	F	VP	FP	FN	r	p	F	VP	FP	FN	r	p	F
1	41	10	12	0,77	0,80	0,79	48	9	5	0,91	0,84	0,87	47	1	6	0,89	0,98	0,93
2	46	7	14	0,77	0,87	0,81	52	15	8	0,87	0,78	0,82	47	1	13	0,78	0,98	0,87
3	42	3	17	0,71	0,93	0,81	52	11	7	0,88	0,83	0,85	50	0	9	0,85	1,00	0,92
4	43	3	18	0,70	0,93	0,80	57	6	4	0,93	0,90	0,92	55	1	6	0,90	0,98	0,94
5	44	4	20	0,69	0,92	0,79	55	19	9	0,86	0,74	0,80	54	1	10	0,84	0,98	0,91
6	47	5	18	0,72	0,90	0,80	54	12	11	0,83	0,82	0,82	44	1	21	0,68	0,98	0,80
7	44	7	17	0,72	0,86	0,79	56	8	5	0,92	0,88	0,90	53	0	8	0,87	1,00	0,93
8	50	4	15	0,77	0,93	0,84	60	14	5	0,92	0,81	0,86	57	1	8	0,88	0,98	0,93
9	47	6	17	0,73	0,89	0,80	55	16	9	0,86	0,77	0,81	48	1	16	0,75	0,98	0,85
10	43	7	17	0,72	0,86	0,78	50	13	10	0,83	0,79	0,81	47	1	13	0,78	0,98	0,87
11	46	7	11	0,81	0,87	0,84	53	9	4	0,93	0,85	0,89	50	2	7	0,88	0,96	0,92
12	49	5	15	0,77	0,91	0,83	54	25	10	0,84	0,68	0,76	47	0	17	0,73	1,00	0,85
13	39	3	12	0,76	0,93	0,84	45	13	6	0,88	0,78	0,83	42	3	9	0,82	0,93	0,88
14	42	4	19	0,69	0,91	0,79	57	16	4	0,93	0,78	0,85	53	0	8	0,87	1,00	0,93
15	31	0	30	0,51	1,00	0,67	53	17	8	0,87	0,76	0,81	46	3	15	0,75	0,94	0,84
16	48	1	16	0,75	0,98	0,85	60	13	4	0,94	0,82	0,88	54	0	10	0,84	1,00	0,92
17	42	6	14	0,75	0,88	0,81	52	19	4	0,93	0,73	0,82	50	3	6	0,89	0,94	0,92
18	47	5	14	0,77	0,90	0,83	56	13	5	0,92	0,81	0,86	50	0	11	0,82	1,00	0,90
Total	791	87	296	0,73	0,90	0,81	969	248	118	0,89	0,8	0,84	894	19	193	0,82	0,98	0,89

Em que: VP: verdadeiro positivo; FP: falso positivo; FN: falso negativo; r: rejeito; p: precisão; F: F-score; Parc.: parcela.

FONTE: A autora (2018).

Na FIGURA 33 estão apresentados os resultados de detecção nos diferentes métodos aplicados, exemplificado nas parcelas 18 e 1, respectivamente com o melhor e pior F-score com a ferramenta TreeDetect utilizando a banda NIR. Observa-se que o uso do CHM na ferramenta TreeDetect e o rLiDAR tenderam a apresentar mais erros do tipo FP, detectando mais que um ponto em algumas copas.

FIGURA 33 - DETECÇÃO DE ÁRVORES NAS PARCELAS DO TALHÃO PINUS 2



FONTE: A autora (2018).

Os maiores erros de FN foram observados com uso do eCognition e ITD, principalmente em copas menores. Já a ferramenta TreeDetect com uso da banda NIR apresentou tanto erros do tipo FN, em copas menores principalmente, como FP nas copas maiores e heterogêneas.

Por fim, a análise geral da detecção para os três talhões está apresentada nas TABELA 43 e 44, em relação ao número de árvores detectadas e a qualidade da detecção, respectivamente. Observa-se que ambos os métodos com a ferramenta TreeDetect não apresentam diferença significativa quando se comparou os resultados experimentais com o número real de árvores em todos os talhões.

TABELA 43 – RESULTADO GERAL DA DETECÇÃO DE ÁRVORES COM TODOS OS MÉTODOS TESTADOS NOS TRÊS TALHÕES

Método	<i>Eucalyptus</i>	<i>Pinus 1</i>	<i>Pinus 2</i>
TreeDetect NIR	571 ^{ns}	842 ^{ns}	1.036 ^{ns}
TreeDetect CHM	623 ^{ns}	700 ^{ns}	1.133 ^{ns}
eCognition	562 ^{ns}	604*	878*
rLiDAR	581 ^{ns}	547*	1.217 ^{ns}
ITD	512 ^{ns}	768 ^{ns}	913*

Em que: * e ns: respectivamente, significativo e não significativo pelo teste Qui-quadrado a 95% de probabilidade.
FONTE: A autora (2018).

Observa-se, no ranqueamento geral, que o método com a ferramenta TreeDetect com banda NIR apresentou o melhor resultado para a qualidade de detecção, sendo o primeiro colocado em todos os casos. Subsequentemente, a ferramenta TreeDetect com o CHM e o ITD apresentam-se em segundo lugar e em terceiro estão os métodos que utilizaram o eCognition e o rLiDAR.

TABELA 44 – RANQUEAMENTO DA QUALIDADE DE DETECÇÃO DOS MÉTODOS TESTADOS NOS TRÊS TALHÕES

Método	F-score			Posição			Média
	<i>Eucalyptus</i>	<i>Pinus 1</i>	<i>Pinus 2</i>	<i>Eucalyptus</i>	<i>Pinus 1</i>	<i>Pinus 2</i>	
TreeDetect NIR	0,96	0,8	0,89	1	1	1	1,00
TreeDetect CHM	0,74	0,74	0,88	3	2	2	2,33
ITD	0,71	0,74	0,89	4	2	1	2,33
eCognition	0,83	0,71	0,81	2	3	4	3,00
rLiDAR	0,71	0,74	0,84	4	2	3	3,00

FONTE: A autora (2018).

3.5 DISCUSSÃO

O talhão de *Eucalyptus*, de maneira geral, apresentou os melhores resultados de detecção, em que os erros variaram de 1,5% até 13,2% (rLiDAR e ITD, respectivamente) nas parcelas amostradas e de 2,7% até 12,1% (eCognition e ITD,

respectivamente) para o talhão total. Quando avaliada a qualidade da detecção, observa-se que o uso da ferramenta TreeDetect com a banda NIR apresentou os melhores resultados, destacando-se principalmente pelo baixo número de falsos positivos. O resultado do uso do CHM com a ferramenta TreeDetect apresentou maiores erros se comparado ao uso da banda NIR. No caso do talhão *Eucalyptus*, acredita-se que devido ao tamanho e formato das copas, mais arredondadas, a identificação de um único ponto máximo tenha sido difícil, portanto a ocorrência de falso positivos com o CHM foi maior. Nesse caso, também foram observados falsos negativos, geralmente relacionados a árvores menores ou bifurcadas (com duas copas visíveis, porém somente uma detectada). No talhão *Eucalyptus* observou-se também que todos os métodos, com exceção do TreeDetect com o CHM, apresentaram maior número de falsos negativos do que falsos positivos, de forma que se confirma que a maioria dos métodos subestimou o real número de árvores.

O erro de 3,9% encontrado com a ferramenta TreeDetect usando a banda NIR no talhão como um todo pode ser comparado a valores de detecção encontrados com uso de dados LiDAR, como observado por Oliveira et al. (2012) que utilizando o método de locais máximos encontraram erros entre 1,15% e 3,42%. O resultado aqui encontrado também é superior ao sucesso de detecção de apenas 58% das árvores em plantios de *Eucalyptus* utilizando imagens de alta resolução observado por Shinzato et al. (2017). Ainda, os resultados aqui encontrados são coerentes, cujos erros variaram entre 0,79% e 8,90% usando LiDAR e algoritmo de detecção de local máxima em talhões de *Eucalyptus* com distintas idades (OLIVEIRA et al., 2014). O único trabalho que utilizou detecção de plantios de *Eucalyptus* com dados VANT apresentou detecção de cerca de 79,6% das árvores com erros de omissão e comissão de 20,8% e 6,5% em condições de luminosidade ideal e com o algoritmo de local máxima (GUERRA-HERNÁNDEZ et al., 2018).

O talhão *Pinus* 1 exibiu os maiores valores de erro, tanto nas parcelas (entre 4,1% e 25,1%), como para todo o talhão (entre -2,3% e -30,6%). Nesse talhão, os menores erros para o talhão foram observados com o ITD, e no caso das parcelas com a ferramenta TreeDetect, porém utilizando o CHM como arquivo de entrada. Apesar disso, pela análise de qualidade da detecção, a ferramenta TreeDetect, utilizando a banda NIR como arquivo de entrada, apresentou o melhor valor de F-score na maioria das parcelas e no valor geral, portanto o melhor balanço entre falsos negativos e falsos positivos. O talhão *Pinus* 2 apresentou resultados melhores em

relação ao *Pinus* 1, com erro variando entre 4,2 e 19,2% nas parcelas, e -4,7 e 22,7% na área total do talhão. O menor erro foi observado com a ferramenta TreeDetect, utilizando o CHM nas parcelas e no talhão total. Na análise de qualidade, ambos os métodos que utilizaram a ferramenta TreeDetect com a banda NIR e a ferramenta ITD apresentaram o melhor resultado em 9 parcelas e um F-score médio de 0,89, que é ligeiramente superior do que o obtido com uso da ferramenta TreeDetect com o CHM de 0,88 de F-score.

Os resultados encontrados com a ferramenta TreeDetect e uso da banda NIR, com erro no talhão como um todo de -15,5% e 5,9%, respectivamente para os dois talhões de *Pinus*, podem ser comparados com os resultados de detecção entre 66,7% e 100% em talhões de *Pinus* usando dados LiDAR e algoritmo de local máxima com janela variável encontrados por Zandoná, Lingnau e Nakajima (2008). Em relação a dados VANT em floresta conífera (natural e com espaçamento grande), Thiel e SCHMullius (2017) encontraram uma detecção de aproximadamente 93,2% das árvores utilizando o algoritmo de local máxima, resultados inclusive superiores à detecção utilizando dados LiDAR, de 78% nesse mesmo local.

É interessante observar que o método que mais se aproximou do número total de árvores no talhão não necessariamente apresentou o melhor ou um dos melhores resultados quando foi analisada a qualidade de detecção nas parcelas amostrais. No talhão *Eucalyptus*, o método mais próximo do total de árvores foi com o eCognition, que apresentou um F-score inferior a ferramenta TreeDetect com uso da banda NIR. No talhão *Pinus* 1, o valor mais próximo ao número total foi observado com o ITD, enquanto que a ferramenta TreeDetect com a banda NIR como entrada apresentou o melhor F-score. Já no talhão *Pinus* 2, o número de árvores total foi mais próximo do real com a ferramenta TreeDetect usando o CHM, enquanto que a TreeDetect com a banda NIR apresentou o melhor F-score empatada com o obtido se usando ITD. Isso acontece porque a ocorrência de ambos erros de omissão e comissão podem acabar mascarando os erros na contagem total (TANHUANPÄÄ et al., 2016), de forma que, para avaliar a qualidade dos métodos, é importante a análise de fatores como o F-score.

A ferramenta TreeDetect apresentou resultados de detecção considerados satisfatórios para os três talhões avaliados, sendo que, independentemente do arquivo de entrada (banda NIR ou CHM), o número de árvores detectadas não diferiu significativamente dos dados observados em campo em todos os talhões ao nível de

95% de probabilidade. Apesar de ambos arquivos de entrada apresentarem resultados satisfatórios, o uso da banda NIR apresentou melhores resultados quando comparado ao CHM em todos os casos nas análises de qualidade. Os resultados aqui encontrados podem ser comparados com outros estudos aplicando dados VANT, como F-score variando entre 0,73 e 0,95 com uso de local máxima em área de floresta aberta (MOHAN et al., 2017), e ao F-score variando entre 0,74 e 0,90 no método de detecção baseado no pré-processamento de imagens e utilização de segmentação de bacias em florestas de coníferas e folhosas com diferentes densidades (HUANG; LI; CHEN, 2018).

O uso do eCognition foi adequado no talhão *Eucalyptus*, atingindo resultados muito próximos aos obtidos pelo TreeDetect, porém apresentou resultados muito inferiores nos dois talhões de *Pinus*. Nos talhões de *Pinus* observou-se uma grande dificuldade na segmentação, que pode ser explicado pela razão das copas serem heterogêneas, principalmente no talhão *Pinus* 1, que apresentava muitas copas quebradas ou danificadas. Esse padrão também pode ser observado na superioridade do uso da ferramenta TreeDetect com a banda NIR no talhão *Eucalyptus*, devido à facilidade de separação das copas e seus respectivos entornos. Dessa forma, apesar desse método ser muito promissor por não depender do MDT, sua aplicação depende muito das condições da área e da homogeneidade espectral das copas, geralmente bastante heterogêneas em imagens de alta resolução, como em dados de VANT (HUANG; LI; CHEN, 2018), pois altas resoluções são capazes de detectar maiores detalhes de variação de cores e luminosidade.

É possível a construção de outros tipos de segmentação e classificação no eCognition, porém tarefas muito complexas não são viáveis em aplicações em grande escala, visto que a segmentação precisa ser otimizada para cada tipo de copa, e a classificação somente pode ser padronizada se as imagens forem radiometricamente calibradas, pois, sem esse processo, os valores de número digital são inconsistentes e não adequados para quantificações e análises recorrentes (MANFREDA et al., 2018).

O uso dos métodos com o rLiDAR e com o ITD apresentaram resultados relativamente similares em todos os talhões, sendo que o rLiDAR apresentou diferença significativa no talhão *Pinus* 1 e o ITD no *Pinus* 2. Apesar de apresentarem diferença significativa nesses casos, os resultados não foram muito inferiores aos demais métodos e, portanto, ambos os métodos poderiam ser aplicados na detecção

de árvores, desde que haja a disponibilidade de um MDT para normalizar os dados, pois ambos trabalham com os valores de elevação das copas. O mesmo vale para o uso da TreeDetect com o CHM como entrada. Dessa forma, mesmo que esses métodos possam ser aplicados, a disponibilidade do MDT limitará seu uso em diversos cenários, principalmente em pequenas áreas onde não existem dados LiDAR para a modelagem do terreno e não haja um dossel aberto para a construção do MDT a partir das imagens VANT (BIRDAL; AVDAN; TÜRK, 2017; MOHAN et al., 2017). Os métodos baseados em modelos de altura têm certas vantagens, principalmente em áreas em que segmentações e classificações são difíceis de aplicar, como se observa nos dois talhões de *Pinus*. Já, quando comparados os métodos que utilizam CHM ou nuvem normalizada, destaca-se que o primeiro método geralmente é mais simples em termos computacionais, porém a interpolação dos pontos pode ocasionar a perda de informação, principalmente em árvores menores (KATHURIA et al., 2016).

Ainda, em relação ao rLiDAR e outros algoritmos de locais máximos, é importante destacar que os resultados são altamente influenciados pelos parâmetros de suavização do CHM e do tamanho da janela de busca (MOHAN et al., 2017; PANAGIOTIDIS et al., 2016). Em geral, é recomendada a suavização do CHM, mesmo em dados VANT (MOHAN et al., 2017), porém, em testes com a ferramenta, observou-se que o CHM original foi mais efetivo em alguns dos talhões, possivelmente porque as nuvens de pontos VANT já tendem a suavizar as copas. Apesar disso, no talhão *Pinus* 1 optou-se por aplicar a janela de suavização, pois devido a irregularidade do dossel (com muitas copas quebradas, bifurcadas e outros), quando o CHM original era selecionado, o número de falsos positivos era muito grande. Resultado semelhante também foi observado por Guerra-Hernández et al. (2018), tendo concluído que o uso de CHM derivado de LiDAR necessita da aplicação de uma janela de suavização maior do que CHM derivado de dados VANT para a correta detecção de árvores de *Eucalyptus* utilizando-se de um filtro de local máxima.

Observou-se, também, que a maior parte dos erros de comissão (falsos positivos) ocorre em copas grandes, especialmente irregulares, como observadas principalmente no talhão *Pinus* 1. Nesse talhão em especial, diversas árvores que sofreram ataques de macaco-prego desenvolveram galhos laterais, que são detectados como copas em ambos métodos baseados na resposta espectral como nos modelos de altura de copa. Resultados similares foram observados em outros estudos que apontam ser o processo de superestimação do número de árvores

resultado da resolução muito alta dos dados e de altas variações espectrais (BONNET; LISEIN; LEJEUNE, 2017; HUANG; LI; CHEN, 2018; TANHUANPÄÄ et al., 2016). Ainda, similar ao que ocorre no talhão *Pinus* 1, Thiel e SCHMullius (2017) observaram erros de comissão em áreas em que galhos das árvores se estendiam para aberturas na copa.

Já os erros de omissão ocorrem principalmente em copas menores, como de árvores bifurcadas abaixo do dap e rebrotas. No talhão *Eucalyptus* são observados, entretanto, falsos negativos em copas de tamanho grande, principalmente para os métodos com base na altura da copa (ITD, rLiDAR, e TreeDetect com CHM), possivelmente devido à maior dificuldade de identificação de um ponto de topo em árvores folhosas (BAENA et al., 2017). Dessa forma, uma limitação deve ser considerada cuidadosamente na aplicação de dados VANT na detecção de árvores, ou seja, a presença de árvores suprimidas, tanto para métodos baseados em ortomosaico como em modelos de copa (BIRDAL; AVDAN; TÜRK, 2017; BONNET; LISEIN; LEJEUNE, 2017; MOHAN et al., 2017). Isso ocorre porque a presença de copas em tamanhos irregulares dificulta a definição dos parâmetros de detecção (AYREY et al., 2017; KATHURIA et al., 2016), e a reconstrução dessas árvores na nuvem de pontos VANT é dificultada pela oclusão delas em muitas imagens (NEVALAINEN et al., 2017). A densidade, ou espaçamento de plantio, também exerce uma grande influência nos resultados de detecção, pois espaçamentos pequenos ocasionam a sobreposição de partes da copa (ROBERTS et al., 2005). Ainda, a dificuldade de detecção de algumas árvores pode ser resultado da suavização dos topos da copas, como é observado em nuvens de pontos de VANT, se comparadas ao LiDAR (BONNET; LISEIN; LEJEUNE, 2017; LISEIN et al., 2013).

As aplicações com dados VANT também tem resultado influenciado pela qualidade das imagens tomadas, pois variações de luz e presença de sombra causam problemas tanto no ajustamento das imagens para a construção do ortomosaico e nuvem de pontos (BEMIS et al., 2014; WHITEHEAD; HUGENHOLTZ, 2014), como interfere significativamente na aplicação de técnicas de segmentação e classificação espectral (BONNET; LISEIN; LEJEUNE, 2017). Mesmo em algoritmos baseados em detecção de locais máximos, a realização de voos em condições de luminosidade não ideais (dias nublados e com baixa luminosidade), resulta em detecção de um número muito inferior de árvores do que realmente existe (GUERRA-HERNÁNDEZ et al., 2018). Ainda, variações no terreno e nas condições da floresta, como densidade,

também são importantes fatores no sucesso de detecção de árvores a partir de dados VANT (GUERRA-HERNÁNDEZ et al., 2018) ou mesmo LiDAR (KWAK et al., 2010).

3.6 CONCLUSÕES

Este trabalho viabilizou o desenvolvimento de uma ferramenta para detecção de árvores a partir de produtos derivados de VANT, como ortomosaicos e CHMs, valendo-se da definição de alguns parâmetros de entrada e mínima intervenção manual. A ferramenta desenvolvida, chamada TreeDetect, foi aplicada com sucesso nos três talhões objetos deste estudo, o que possibilitou a estimativa dos seus respectivos números totais de árvores. A ferramenta foi aplicada com dois arquivos de entrada distintos, sendo eles a banda NIR e o CHM, sendo que a banda NIR mostrou-se superior na maior parte dos casos.

A qualidade da ferramenta, frente a outros métodos de detecção já comumente implementados foi realizada com uso do eCognition, rLiDAR e ITD. Todos os métodos se mostraram promissores, porém pela análise de qualidade, observa-se a superioridade da ferramenta TreeDetect, uma vez que apresentou diferença não significativa em todas as situações e o melhor desempenho avaliado pelo F-score. Os métodos apresentaram melhores resultados no talhão *Eucalyptus*, enquanto que nos talhões de *Pinus* houve maior dificuldade de detecção em todos os métodos, possivelmente devido a heterogeneidade espectral desses talhões e ao grande número de copas danificadas no talhão de *Pinus* mais velho.

Os resultados encontrados com a ferramenta TreeDetect nas particulares situações examinadas são comparáveis com resultado obtidos com uso de dados do LiDAR em outros estudos. A ferramenta ainda se destaca pela possibilidade de utilização das bandas espectrais para a detecção, portanto sem necessidade da normalização dos dados a partir de um MDT.

Sugere-se no futuro a realização da comparação entre os resultados da ferramenta TreeDetect com os algoritmos implementados no pacote LidR, lançado após a finalização dos experimentos aqui apresentados.

CAPÍTULO 4: ESTIMATIVA DE VARIÁVEIS DENDROMÉTRICAS DERIVADAS DE IMAGENS OBTIDAS POR MEIO DE SENSORES PASSIVOS EMBARCADOS EM VEÍCULO AÉREO NÃO TRIPULADO

4.1 INTRODUÇÃO

A utilização de dados de sensoriamento remoto em ambientes florestais é uma prática bastante comum, podendo ser relacionada a mapeamentos e delimitações de áreas, estratificação, obtenção de variáveis estimativas e, até mesmo, a mensuração de variáveis biométricas sem necessidade ou redução de atividades em campo (KERSHAW JR. et al., 2017). O tipo de aplicação e o nível de detalhamento, porém, são geralmente relacionados ao tipo do sensor disponível. Em termos de obtenção de variáveis dendrométricas, geralmente necessita-se de dados com resoluções entre média e alta, e em geral podem ser realizadas estimativas em nível de área ou em nível de árvore individual, sendo que as últimas requerem resoluções altas ou muito altas (LISEIN et al., 2013; WHITE et al., 2016).

Dentre os tipos de dados de sensoriamento remoto que podem ser utilizados, destacam-se imagens de satélite, fotografias aéreas, radares, sensores hiperespectrais e LiDAR aéreo ou terrestre (ALS e TLS, respectivamente), sendo que os sensores LiDAR são os mais utilizados em termos de obtenção de variáveis quantitativas, devido à sua capacidade de penetração no dossel florestal (KAARTINEN et al., 2012). Apesar da grande capacidade dos sensores LiDAR em caracterizar o perfil vertical da floresta, seu uso é limitado devido ao custo alto de aquisição (MALTAMO; NÆSSET; VAUHKONEN, 2014). Ainda, a maior parte das aplicações desenvolvidas até o momento são restritas em nível de área, devido à necessidade de uma densidade de pulsos muito alta para aplicações em nível de árvore individual, acarretando em custos ainda maiores na coleta de dados (WHITE et al., 2016). Apesar dos métodos de área serem mais consolidados e fáceis de incorporar ao sistema amostral dos inventários florestais de campo (HYYPÄ et al., 2008; WULDER et al., 2012), os métodos de árvore individual podem apresentar estimativas mais precisas, e não são tão dependentes de dados de campo para a construção de modelos estimativos (HYYPÄ et al., 2008). Dessa forma, estimativas em nível individual são preferenciais em casos em que existam dados com resolução suficiente para a correta identificação das árvores individualmente.

Nesse contexto, o uso dos Veículos Aéreos Não Tripulados (VANTs) nos últimos anos tornou-se muito atrativo no meio florestal, pois esses veículos aéreos permitem a obtenção de dados de alta resolução e com custo muito inferior ao de outras plataformas disponíveis anteriormente (PÁDUA et al., 2017; WHITEHEAD et al., 2014). Os VANTs destacam-se também pela facilidade de manuseio, permitindo a coleta de dados com flexibilidade e alta taxa de revisita (ANDERSON; GASTON, 2013), e a incorporação de diversos sensores (WHITEHEAD et al., 2014), sejam passivos ou ativos, entre outros. Ainda, o desenvolvimento de técnicas de processamento de imagens VANT com a integração de técnicas de visão computacional, como o *Structure from Motion* (SfM), permitem a obtenção de diversos produtos a partir de imagens de sensores passivos, incluindo ortomosaicos, modelos digitais de superfície e nuvens de pontos 3D (WHITEHEAD; HUGENHOLTZ, 2014). Dessa forma, dados derivados de plataforma VANT podem fornecer informações tanto espectrais como de estrutura (MDS, CHM e outros). Uma das limitações, porém, do uso de sensores passivos em VANT é que estes não permitem a obtenção de dados abaixo da superfície de objetos, portanto não é possível mapear o terreno em áreas de floresta fechada (WHITE et al., 2016). Dada essa limitação, somente é possível a obtenção de dados da altura de florestas com dosséis fechados a partir da normalização dos dados VANT com um MDT (Modelo Digital do Terreno) de outra fonte, como LiDAR (LISEIN et al., 2013).

Até o momento, os trabalhos relativos a estimativas de variáveis dendrométricas, a partir de dados VANT, referem-se a estimativas de alturas (DANDOIS; ELLIS, 2013; JENSEN; MATHEWS, 2016), biomassa (DANDOIS; ELLIS, 2013), volume (BONNET; LISEIN; LEJEUNE, 2017; GIANNETTI et al., 2018; PULITI et al., 2015), área basal (BONNET; LISEIN; LEJEUNE, 2017; LISEIN et al., 2013), entre outros, em nível de área. Existem também alguns trabalhos em nível individual, relacionados à altura individual (BONNET; LISEIN; LEJEUNE, 2017; LISEIN et al., 2013; WALLACE et al., 2016), e em alguns casos diâmetro de copa, diâmetro a 1,3 m e biomassa (GUERRA-HERNÁNDEZ et al., 2017; PANAGIOTIDIS et al., 2016). Na maioria dos estudos, até momento, tem-se utilizado de métricas derivadas de altura (altura máxima, percentis, entre outras), similar ao procedimento realizado com dados LiDAR, e poucos tem explorado a utilização das variáveis espectrais para estimativas de alturas e volumes, podendo-se citar como exemplos Bonnet, Lisein e Lejeune (2017) e Giannetti et al. (2018). Ainda, esses trabalhos são, em sua maioria,

desenvolvidos em florestas temperadas com relativamente baixa densidade de indivíduos, muito distintos dos padrões de florestas plantadas no Brasil.

Considerando o cenário apresentado, objetivou-se o desenvolvimento de equações estimativas de variáveis dendrométricas em nível de árvore individual, a partir de dados obtidos com sensores passivos embarcados em plataforma VANT. Foram avaliados distintos sensores, assim como a utilização de variáveis espectrais, estruturais e de textura, bem como, a combinação dessas.

4.2 OBJETIVOS

O objetivo geral deste capítulo foi avaliar a possibilidade de geração de estimativas das variáveis dendrométricas altura, dap e volume de árvores individuais a partir de produtos gerados pela plataforma VANT embarcada com sensores passivos. De maneira específica, objetivou-se:

- Construir estimativas de altura, dap e volume utilizando-se de distintas variáveis derivadas de VANT, sendo elas variáveis espectrais, estruturais e texturais;
- Avaliar a contribuição de cada tipo de variável derivada de VANT e sensor passivo nas estimativas e verificar qual combinação resulta nas melhores estimativas;
- Obter as estimativas com dados de câmeras passivas RGB, NIR e Multiespectral e avaliar o efeito nelas da escolha da câmera;
- Aplicar as equações desenvolvidas nas árvores detectadas com a ferramenta TreeDetect e comparar a estimativa do volume total do talhão com o valor do censo.

4.3 MATERIAL E MÉTODOS

4.3.1 Área de estudo e base de dados

A área de estudo utilizada neste capítulo compreende três talhões de floresta plantada, sendo eles denominados *Eucalyptus* (*Eucalyptus urograndis*, 5 anos), *Pinus* 1 (*Pinus taeda*, 16 anos) e *Pinus* 2 (*Pinus taeda*, 7 anos). Os talhões estão localizados em Telêmaco Borba-PR, são propriedade da empresa florestal Klabin S.A., parceira

na realização deste estudo. Detalhes sobre os talhões e a região geográfica estão apresentados no Capítulo 2.

A base de dados de campo utilizada compreende as informações obtidas em censo nos três talhões, no qual foram mensurados altura e dap (diâmetro à altura do peito – 1,3 m) e informações qualitativas, como a presença de danos, bifurcações, entre outros. Para cada árvore foram tomados os valores de linha e posição na linha, de forma que as árvores pudessem ser alocadas geograficamente com base nos dados das planilhas de campo e os ortomosaicos disponíveis. Os volumes individuais das árvores foram estimados com os polinômios de 5° grau ajustados pela empresa florestal que forneceu os dados.

Além dos dados de campo, foram utilizadas informações obtidas com a plataforma VANT eBee Ag, embarcada com três distintas câmeras passivas. Essas câmeras são denominadas de RGB, NIR e Multi. A câmera RGB é do modelo DSC-WX220, tem 18,8 MP de resolução e apresenta as bandas Vermelha (Red), Verde (Green) e Azul (Blue). A câmera NIR é do modelo S110 NIR, tem 12 MP de resolução e apresenta as bandas Verde, Vermelha e NIR. Já a câmera Multiespectral (Multi) é do modelo Multispec 4C, tem 1,2 MP de resolução e apresenta, separadamente, as bandas Verde, Vermelha, Red edge e NIR.

Os talhões foram imageados com a utilização da plataforma VANT e cada uma das câmeras separadamente. O talhão *Eucalyptus* é o único que não apresenta dados da câmera RGB, devido a um defeito na câmera. Os voos com o VANT foram realizados de forma a se obter um GSD de 5 cm, conforme detalhes apresentados no capítulo 2. As imagens tomadas foram processadas com o *software* Pix4D e obteve-se um ortomosaico, uma nuvem de pontos e um modelo digital de superfície (MDS) para cada câmera em cada talhão. No caso da câmera Multi, diferentemente das outras duas, não foi gerado um ortomosaico, mas sim um mapa (ou imagem) de reflectância radiometricamente calibrado para cada uma das quatro bandas espectrais. Com base no MDS e em um MDT obtido com dados coletados com sensor LiDAR aéreo foi também calculado um modelo digital de altura de copa (CHM) para cada situação. Maiores detalhes sobre as câmeras, procedimentos de coleta e processamento dos dados VANT e normalização dos modelos de superfície com os dados LiDAR, estão apresentados no Capítulo 2.

4.3.2 Delimitação das copas individuais


A primeira etapa do desenvolvimento das estimativas dendrométricas individuais foi a delimitação das copas das árvores. Essa etapa permitiu a extração de informações espectrais (e estruturais) derivadas dos produtos de VANT em nível de árvores individual, porém englobando toda a área compreendida por uma árvore. Esse tipo de abordagem é útil, pois permite a obtenção de estatísticas sobre os dados, como valores médios, desvios e outros que são úteis no processo estimativo.

Para a delimitação das copas utilizou-se a função *ForestCAS*, implementada no pacote para R *rLiDAR* (SILVA et al., 2017a). A delimitação é baseada em coordenadas *x*, *y* e *z* das árvores detectadas ou alocadas, de um CHM e dos parâmetros de máximo raio de copa (*maxcrown*) e limite de exclusão (*exclusion*). O limite de exclusão é um percentual que define o limite de máxima diferença de altura que um pixel pode ter em relação ao valor máximo de altura da árvore, para ser considerado a mesma copa (SILVA et al., 2017a).

Como cada uma câmera derivou um CHM (MDS normalizado pelo MDT LiDAR), a delimitação de copas foi realizada para cada uma das câmeras de forma separada. No caso da câmera Multi, foram geradas nuvens de pontos para cada uma das bandas espectrais e, portanto, nesse caso utilizou-se somente a nuvem de pontos da banda NIR para a normalização e geração de CHM. Em todos os casos o CHM foi reamostrado para a resolução de 50 cm para ser utilizado na delimitação, pois demonstrou um resultado melhor. Similarmente, quando realizada a detecção com o *rLidar* no capítulo 3, também se observou melhores resultados quando o CHM foi reamostrado para 50 cm de resolução. As coordenadas geográficas das árvores foram obtidas a partir das árvores mensuradas no censo e manualmente alocadas nos ortomosaicos, de forma que, para todas as câmeras, foram utilizadas as mesmas coordenadas. Em alguns casos, em que árvores foram observadas em campo, mas não foram visíveis nas imagens (como quebradas, bifurcadas, dominadas e outras), essas foram desconsideradas porque não seria possível fazer a correspondência entre dados VANT e valores de campo.

Foram realizados alguns testes para a definição dos parâmetros *maxcrown* e *exclusion*, que foram definidos, respectivamente, como 1,5 e 0,5 para os talhões *Eucalyptus* e *Pinus* 2, e 2 e 0,5 para o talhão *Pinus* 1. A escolha dos melhores parâmetros foi feita com base em análise visual da delimitação sobre um ortomosaico,

e optou-se por priorizar a delimitação que eliminasse as áreas de sombra entre as copas, mesmo que excluísse parte delas, de forma que as informações obtidas se referissem somente às copas. Exemplos dos resultados da delimitação, para a câmera NIR, estão apresentados na FIGURA 34. A partir dos polígonos das copas, foram obtidas as informações a serem utilizadas como variáveis nos modelos estimativos.



FONTE: A autora (2018).

4.3.3 Obtenção de variáveis para os modelos estimativos

A seleção das variáveis independentes preditivas das variáveis dependentes dap, altura e volume foi realizada levando-se em consideração os produtos obtidos a partir de cada câmera utilizada nos três talhões. As variáveis foram então agrupadas em quatro grupos, sendo eles: variáveis estruturais, variáveis espectrais, variáveis de textura relativas aos arquivos estruturais e variáveis de textura relativas aos arquivos espectrais.

Em todos os casos, os arquivos de entrada, sejam CHM, MDS ou bandas, foram reamostrados para a resolução espacial de 50 cm, de forma que todos os arquivos apresentaram a mesma resolução, como observado em Giannetti et al. (2018). Essa decisão foi baseada em alguns testes prévios, quando se observou que a redução para uma resolução menor apresentava melhores resultados estimativos, principalmente nos modelos baseados em CHM e MDS, provavelmente devido à presença de ruídos que são suavizados na reamostragem. Além disso, a reamostragem para uma resolução menor diminui o tempo de processamento dos

dados. A resolução original desses dados variou entre 5 e 12 cm aproximadamente, conforme os valores apresentados no capítulo 2.

No caso das variáveis estruturais, foram consideradas a área de copa (m^2) delimitada e estatísticas derivadas do CHM e MDS. No caso da câmera multiespectral é gerada uma nuvem de pontos para cada banda, portanto neste trabalho optou-se por gerar o CHM com a nuvem de pontos da banda NIR. Em relação às variáveis espectrais, foram calculadas estatísticas relativas a cada banda espectral de cada câmera, assim como algumas matemáticas de bandas. Ambas as variáveis estruturais e espectrais estão apresentadas na TABELA 45.

No caso das câmeras NIR e RGB calculou-se a intensidade, baseada no trabalho de Giannetti et al. (2018), dada por (5). No caso da câmera multiespectral foram calculados os índices NDVI (*Normalized Difference Vegetation Index*) e NDRE (*Normalized Difference Red Edge index*), conforme (6) e (7).

$$Intensidade = 0,2 \cdot B1 + 0,72 \cdot B2 + 0,07 \cdot B3 \quad (5)$$

Em que: para a câmera NIR, B1, B2 e B3 = Vermelha, Verde e NIR; e para câmera RGB, B1, B2 e B3 = Vermelha, Verde e Azul.

$$NDVI = (NIR - V) / (NIR + V) \quad (6)$$

$$NDRE = (NIR - RE) / (NIR + RE) \quad (7)$$

Em que: NIR, V e RE = respectivamente, a reflectância das bandas NIR, Vermelha e Red Edge.

TABELA 45 - VARIÁVEIS ESTRUTURAIS E ESPECTRAIS UTILIZADAS NAS ESTIMATIVAS

	Câmera	Arquivo de entrada	Estatística	Variáveis
		Copas	área	Área
Estrutural	NIR, Multi e RGB	CHM	soma, média, desvio padrão e máximo	CHM_sum, CHM_med, CHM_stdv, CHM_max
		MDS		MDS_sum, MDS_med, MDS_stdv, MDS_max
Espectral	NIR	Banda Vermelha (Red)	soma, média e desvio padrão	Red_sum, Red_med, Red_stdv
		Banda Verde (Green)		Gre_sum, Gre_med, Gre_stdv
		Banda NIR		NIR_sum, NIR_med, NIR_stdv
		Intensidade (RGN)		Intens_sum, Intens_med, Intens_stdv
	RGB	Banda Vermelha (Red)	soma, média e desvio padrão	Red_sum, Red_med, Red_stdv
		Banda Verde (Green)		Gre_sum, Gre_med, Gre_stdv
		Banda Azul (Blue)		Blue_sum, Blue_med, Blue_stdv
		Intensidade (RGB)		Intens_sum, Intens_med, Intens_stdv
	Multi	Refl. Verde (Green)	soma, média e desvio padrão	Gre_sum, Gre_med, Gre_stdv
		Refl. Vermelha (Red)		Red_sum, Red_med, Red_stdv
		Refl. Red-edge (RE)		RE_sum, RE_med, RE_stdv
		Refl. NIR		NIR_sum, NIR_med, NIR_stdv
		NDVI		NDVI_sum, NDVI_med, NDVI_stdv
		NDRE		NDRE_sum, NDRE_med, NDRE_stdv

FONTE: A autora (2018).

As variáveis de textura foram calculadas com o pacote *glcm* para R (ZVOLEFF, 2016), desenvolvido para extrair métricas de textura de arquivos *raster*. As texturas GLMC (*grey-level cooccurrence matrix*) são calculadas com base na análise de quão frequentemente padrões específicos (pixels vizinhos com diferentes níveis de cinza) ocorrem em uma imagem, em certa distância e ângulo definidos, e são comumente utilizadas em classificações de imagens ou até mesmo estimativas de biomassa florestal (CUTLER et al., 2012; LU; BATISTELLA, 2005).

O pacote *glmc* permite o cálculo de sete distintas métricas, sendo que neste trabalho foram utilizadas as texturas de: Variância, Homogeneidade, Contraste, Dissimilaridade, Entropia e Segundo Momento. Essas texturas, e outras, foram propostas por Haralick, Shanmugam e Dinstein (1973) sendo dadas pelas equações 8 até 13, conforme Lu e Batistella (2005).

$$Variância = \sum_{i,j=0}^{N-1} i P_{i,j} (i - ME)^2 \quad (8)$$

$$Homogeneidade = \sum_{i,j=0}^{N-1} i \frac{P_{i,j}}{1 + (i - j)^2} \quad (9)$$

$$Contraste = \sum_{i,j=0}^{N-1} i P_{i,j} (i - j)^2 \quad (10)$$

$$Dissimilaridade = \sum_{i,j=0}^{N-1} i P_{i,j} |i - j| \quad (11)$$

$$Entropia = \sum_{i,j=0}^{N-1} i P_{i,j} (-\ln P_{i,j}) \quad (12)$$

$$Segundo Momento = \sum_{i,j=0}^{N-1} i P_{i,j}^2 \quad (13)$$

Em que: ME = média, $P_{i,j} = V_{i,j} / \sum_{i,j=0}^{N-1} V_{i,j}$, em que $V_{i,j}$ é o valor na célula i,j (linha i e coluna j) de uma janela móvel, e N é o número de linhas ou colunas.

As texturas foram calculadas para ambos os arquivos relativos às características estruturais, como espectrais, conforme as TABELA 46 e 47. Para cada arquivo gerado, foram calculadas as estatísticas de soma, média e desvio padrão, além do valor máximo para os arquivos do tipo estrutura. No caso da câmera

multiespectral, as bandas se referem aos valores de reflectância, conforme calibração radiométrica apresentada no Capítulo 2.

TABELA 46 - VARIÁVEIS DE TEXTURA RELACIONADAS AOS ARQUIVOS ESTRUTURAIS UTILIZADAS NAS ESTIMATIVAS

Câmera	Arquivo entrada	Textura	Estatística	Variáveis
NIR Multi e RGB	CHM	Variância	soma, média, desvio padrão e máximo	CHM_var_sum, CHM_var_med, CHM_var_stdv, CHM_var_max
		Homogeneidade		CHM_hom_sum, CHM_hom_med, CHM_hom_stdv, CHM_hom_max
		Contraste		CHM_con_sum, CHM_con_med, CHM_con_stdv, CHM_co_max
		Dissimilaridade		CHM_dis_sum, CHM_dis_med, CHM_dis_stdv, CHM_dis_max
		Entropia		CHM_ent_sum, CHM_ent_med, CHM_ent_stdv, CHM_ent_max
		Segundo Momento		CHM_2m_sum, CHM_2m_med, CHM_2m_stdv, CHM_2mr_max
	MDS	Variância	soma, média, desvio padrão e máximo	MDS_var_sum, MDS_var_med, MDS_var_stdv, MDS_var_max
		Homogeneidade		MDS_hom_sum, MDS_hom_med, MDS_hom_stdv, MDS_hom_max
		Contraste		MDS_con_sum, MDS_con_med, MDS_con_stdv, MDS_con_max
		Dissimilaridade		MDS_dis_sum, MDS_dis_med, MDS_dis_stdv, MDS_dis_max
		Entropia		MDS_ent_sum, MDS_ent_med, MDS_ent_stdv, MDS_ent_max
		Segundo Momento		MDS_2m_sum, MDS_2m_med, MDS_2m_stdv, MDS_2mr_max

FONTE: A autora (2018).

Em todos os casos, as estatísticas (soma, média, desvio padrão e máximo) foram calculados no *software* Quantum GIS, versão 2.18.3, com o complemento Estatística Zonal, que extrai informações a partir de um arquivo *raster* considerando limites poligonais.

TABELA 47 - VARIÁVEIS DE TEXTURA RELACIONADAS AOS ARQUIVOS ESPECTRAIS UTILIZADAS NAS ESTIMATIVAS

Câmera	Arquivo entrada	Textura	Estatística	Variáveis
NIR, Multi e RGB	Banda Vermelha (Red)	Variância		Red_var_sum, Red_var_med, Red_var_stdv
		Homogeneidade	soma,	Red_hom_sum, Red_hom_med, Red_hom_stdv
		Contraste	média e	Red_con_sum, Red_con_med, Red_con_stdv
		Dissimilaridade	desvio	Red_dis_sum, Red_dis_med, Red_dis_stdv
		Entropia	padrão	Red_ent_sum, Red_ent_med, Red_ent_stdv
		Segundo Momento		Red_2m_sum, Red_2m_med, Red_2m_stdv
	Banda Verde (Green)	Variância		Gre_var_sum, Gre_var_med, Gre_var_stdv
		Homogeneidade	soma,	Gre_hom_sum, Gre_hom_med, Gre_hom_stdv
		Contraste	média e	Gre_con_sum, Gre_con_med, Gre_con_stdv
		Dissimilaridade	desvio	Gre_dis_sum, Gre_dis_med, Gre_dis_stdv
		Entropia	padrão	Gre_ent_sum, Gre_ent_med, Gre_ent_stdv
NIR e Multi	Banda NIR	Segundo Momento		Gre_2m_sum, Gre_2m_med, Gre_2m_stdv
		Variância		NIR_var_sum, NIR_var_med, NIR_var_stdv
		Homogeneidade	soma,	NIR_hom_sum, NIR_hom_med, NIR_hom_stdv
		Contraste	média e	NIR_con_sum, NIR_con_med, NIR_con_stdv
		Dissimilaridade	desvio	NIR_dis_sum, NIR_dis_med, NIR_dis_stdv
		Entropia	padrão	NIR_ent_sum, NIR_ent_med, NIR_ent_stdv
	Banda Azul (Blue)	Segundo Momento		NIR_2m_sum, NIR_2m_med, NIR_2m_stdv
		Variância		Blue_var_sum, Blue_var_med, Blue_var_stdv
		Homogeneidade	soma,	Blue_hom_sum, Blue_hom_med, Blue_hom_stdv
		Contraste	média e	Blue_con_sum, Blue_con_med, Blue_con_stdv
		Dissimilaridade	desvio	Blue_dis_sum, Blue_dis_med, Blue_dis_stdv
Multi	Banda Red-edge (RE)	Entropia	padrão	Blue_ent_sum, Blue_ent_med, Blue_ent_stdv
		Segundo Momento		Blue_2m_sum, Blue_2m_med, Blue_2m_stdv
		Variância		RE_var_sum, RE_var_med, RE_var_stdv
		Homogeneidade	soma,	RE_hom_sum, RE_hom_med, RE_hom_stdv
		Contraste	média e	RE_con_sum, RE_con_med, RE_con_stdv
		Dissimilaridade	desvio	RE_dis_sum, RE_dis_med, RE_dis_stdv
	Banda Red-edge (RE)	Entropia	padrão	RE_ent_sum, RE_ent_med, RE_ent_stdv
		Segundo Momento		RE_2m_sum, RE_2m_med, RE_2m_stdv

FONTE: A autora (2018).

4.3.4 Ajuste das equações e análise de qualidade

Dada a grande quantidade de variáveis explicativas disponíveis, foram construídas equações de regressão múltipla com seleção de variáveis pelo método *stepwise*. Os ajustes foram realizados para cada talhão e cada câmera e considerando 7 cenários distintos, para as variáveis dap, altura e volume, conforme TABELA 48. A correlação entre as variáveis dependentes e independentes foram apresentadas no Apêndice 1.

O ajuste foi realizado com o *software* Statgraphics 18. O método de ajuste selecionado foi o *Forward Stepwise Selection*, com 50 passos máximos, e decisão baseada no *p-value*, sendo que o mínimo valor para a variável ser incluída foi de 0,05. Dessa forma, somente foram incluídas nas equações as variáveis que apresentaram *p-value* menor ou igual a 0,05. Nos casos de equações em que a variável constante

(valor de interceptação da reta com o eixo vertical) não foi significativa, realizou-se novo ajuste excluindo-a.

TABELA 48 - CENÁRIOS DE EQUAÇÕES GERADAS PARA AS ESTIMATIVAS DE DAP, ALTURA E VOLUME

Equação	Tipos de variáveis
1	Estrutural
2	Espectral
3	Textura espectral
4	Textura estrutural
5	Estrutural + espectral
6	Textura estrutural + textura espectral
7	Todas

FONTE: A autora (2018).

Dadas as três câmeras, os 7 cenários testados e as três variáveis, foram gerados: 42 equações para o talhão *Eucalyptus*, sendo 14 para dap, 14 para altura e 14 para volume, visto que nesse talhão somente utilizou-se as câmeras NIR e Multi; e 63 equações para os cada um dos dois talhões de *Pinus*, sendo 21 equações para dap, 21 para altura e 21 para volume.

Para possibilitar a análise dos modelos em dados não utilizados no ajuste, as equações foram elaboradas com uma parte dos dados, enquanto que parte das árvores foi armazenada para validação. Para a validação, foram utilizadas as mesmas árvores selecionadas para análise de qualidade de detecção no Capítulo 3, sendo que essas encontram-se em parcelas circulares amostradas nos talhões, objetivando-se obter cerca de 25% das árvores. Foram utilizadas, para treino (ajuste) e validação, respectivamente, 1.484 e 590 árvores do talhão *Eucalyptus*, 1.897 e 730 árvores do talhão *Pinus* 1, e 2.807 e 1.087 árvores do talhão *Pinus* 2.

As equações foram então avaliadas com base no coeficiente de determinação ajustado ($R^2_{aj.}$) e erro padrão da estimativa relativo ($Syx\%$), calculados para ambos os dados de treino e validação. Para avaliar a melhor equação, foram dadas notas para cada variável ($R^2_{aj.}$ e $Syx\%$) dos dados de treino, sendo que o melhor valor de cada estatística recebeu a nota 1. Os escores de $R^2_{aj.}$ e $Syx\%$ foram somados resultando em uma nota final, que, quanto menor o valor, melhor a equação.

Com relação aos critérios estatísticos, é importante destacar que o R^2 é uma medida estatística muito utilizada, porém que tem sido considerada inadequada por alguns autores, principalmente pela publicação de Anscombe (1973). Dentre os problemas apresentados pelo R^2 está a alta sensibilidade à presença de *outliers* (não

robusto) e ao fato de que o R^2 aumenta conforme a adição de mais parâmetros ao modelo, de forma que não é possível comparar modelos com diferentes números de variáveis (DRAPER; SMITH, 1998; KVALSETH, 1985; SANQUETTA et al., 2018). Com relação ao número de variáveis, deve-se utilizar o $R^2_{aj.}$, pois este corrige o valor de R^2 conforme o número de parâmetros (SANQUETTA et al., 2018).

Apesar dessas críticas, Sanquetta et al. (2018) realizaram um estudo comparando o uso de diversos critérios estatísticos ($R^2_{aj.}$, e $Syx\%$, soma dos resíduos quadrados, e critérios de informação de Akaike e Bayesiano) para a seleção de modelos de biomassa, e observaram que todos os critérios são úteis para seleção de modelos, e convergem para a seleção do mesmo modelo, apesar de que nenhum é eficiente para detectar *outliers* ou viés nos dados, sendo necessário realizar a análise gráfica de resíduos para tanto. Ainda, Sanquetta et al. (2018) observaram que os critérios $R^2_{aj.}$, e $Syx\%$ tem a vantagem de não dependerem do tamanho da amostra e escala da variável, enquanto que os demais critérios testados são dependentes destes fatores. Dessa forma, como o objetivo deste trabalho foi a seleção da melhor equação, considerou-se que a utilização dos critérios $R^2_{aj.}$, e $Syx\%$ juntamente com a análise de resíduos foi adequada.

Foram também calculados os valores da estatística F (F calculado) para cada equação, confrontado com o valor F tabelado ao nível de confiança de 99%. Cabe aqui destacar que nesse estudo não foram avaliadas as condicionantes da regressão linear, como normalidade, independência dos erros, homocedasticidade, ausência de correlação, entre outros. Isso porque essas condições não são essenciais se o objetivo é a estimação, como é o presente caso, porém podem afetar os testes F e t e a estimação dos coeficientes das equações (GUJARATI; PORTER, 2008). Dessa forma, os valores apresentados devem ser utilizados com cautela.

Por fim, foi realizada a análise gráfica dos resíduos em função das variáveis de interesse para as duas melhores equações de cada caso, a fim de observar a presença de tendência nas estimativas. Utilizou-se os resíduos padronizados, que são dados por cada resíduo dividido pelo erro padrão da regressão (GUJARATI; PORTER, 2008). Para permitir a análise de tendências nos gráficos, optou-se por excluir as árvores muito pequenas (dap menor que 8 cm), apesar de que os dados dessas árvores foram considerados nas análises estatísticas. Ainda, nos resultados estão apresentadas as melhores equações, enquanto que as demais podem ser encontradas no Apêndice 2.

4.3.5 Inclusão de fator de correção nas equações preditivas


Dada a observação de tendência nos resíduos das equações ajustadas, em todos os casos superestimando os valores nas menores árvores e subestimando as maiores, foi proposto a adição de um fator de correção baseado em classes de dap, altura e volume.

O fator de correção foi obtido por meio da seguinte sequência:

1) Foi selecionada a equação que apresentou o melhor resultado para cada variável dependente (dap, altura e volume) em cada talhão, conforme descrito no item 4.3.4.

2) Para cada variável dependente foram obtidas seis classes de valores, para cada talhão, baseando-se na distribuição normal de dados. Dessa forma, as classes foram definidas com base nos valores de média (\bar{x}) e desvio padrão (sd) de cada variável, conforme a FIGURA 35.

FIGURA 35 - DIVISÃO DOS DADOS EM CLASSES DE TAMANHO



FONTE: A autora (2018).

3) Para cada classe foram selecionadas 10 árvores aleatoriamente, utilizando os dados especificados no item 4.3.4. Por meio dos valores observados e estimados das 10 árvores foi obtido o fator de correção por meio de um estimador por razão, conforme (14).

$$R_j = \frac{\sum_{i=1}^{10} YO_i}{\sum_{i=1}^{10} YE_i} \quad (14)$$

Em que: R_j é o fator de correção para a classe j ; YO_i é o valor observado da variável dependente Y na classe j para a i -ésima árvore; YE_i é o valor estimado da variável dependente Y na classe j para a i -ésima árvore.

4) O fator de correção obtido foi incluído de maneira multiplicativa na equação definida no Passo 1, conforme (15) e (16).

$$Y_{ji} = f(X_{ji}) (C_j) \quad (15)$$

Em que $C_j = R_j D_j$

Ou seja,

$$Y_{ji} = (\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_m X_{mi})(R_j D_j) \quad (16)$$

Em que: Y_{ji} é a variável dependente na classe j para a i -ésima árvore; $\beta_0, \beta_1, \dots, \beta_m$ são os coeficientes do modelo; e X_{1i}, \dots, X_{mi} são as variáveis independentes na classe j para a i -ésima árvore; R_j é o fator de correção na classe j e D_j é a variável *Dummy* da classe j .

As variáveis *Dummy* (D_j) foram adicionadas para acomodar a relação entre a classe j (cada classe de tamanho definida no Passo 2) e o fator de correção j , sendo dado pela matriz:

$$\begin{array}{c} \text{Classe} \end{array} \begin{bmatrix} D_1 & D_2 & D_3 & \dots & D_j \\ 1 & 1 & 0 & 0 & \dots & 0 \\ 2 & 0 & 1 & 0 & \dots & 0 \\ 3 & 0 & 0 & 1 & \dots & 0 \\ \dots & \vdots & \vdots & \vdots & \ddots & \vdots \\ j & 0 & 0 & 0 & \dots & 1 \end{bmatrix}$$

Em que: D_1, \dots, D_j são as variáveis *Dummy* das classes 1 até j .

O fator de correção é único para cada classe, porém com a inclusão da matriz de variáveis *Dummy*, cada fator é multiplicado pela respectiva classe que ele pertence, de forma que é possível de ser aplicado em uma única equação. As variáveis *Dummy* podem ser utilizadas em diversas situações, como por exemplo em modelos segmentados, em que extra preditores são adicionados a certos segmentos do modelo a partir das variáveis *Dummy* (DRAPER; SMITH, 1998).

5) Tomando-se os novos valores obtidos no Passo 4, foram recalculadas as estatísticas de avaliação da qualidade do ajuste.

4.3.6 Estimativa de volume total com base em árvores detectadas

De forma a avaliar se é possível realmente obter o volume total de um talhão a partir de dados de plataforma VANT com sensores passivos, é importante não somente realizar a construção de equações estimativas, mas também avaliar conjuntamente o efeito da detecção automática de árvores, visto que a identificação manual de todas as árvores é um processo demorado.

Para avaliar os dois efeitos em conjunto, dos erros da detecção e das estimativas, no volume total estimado do talhão, as equações estimativas de volume de cada talhão foram aplicadas nas árvores detectadas com a ferramenta TreeDetect e a banda NIR, visto que esse método de detecção apresentou os melhores resultados. O método e os resultados da detecção foram apresentados no Capítulo 3. Como a detecção foi realizada somente com a câmera NIR, manteve-se o mesmo padrão, sendo o volume total estimado a partir dos dados e equações desenvolvidas para a câmera NIR em cada um dos talhões.

Nesse caso, aplicou-se o mesmo procedimento anterior, em que as coordenadas das árvores detectadas foram obtidas e, a partir dessas, as copas foram delimitadas e as variáveis explicativas para cada árvore detectada foram calculadas. Nesse caso, todas as árvores resultantes da detecção foram utilizadas, incluindo-se, portanto, as árvores erroneamente detectadas. As variáveis explicativas foram aplicadas nas equações estimativas desenvolvidas e o volume estimado de todas as árvores foi somado de forma a se obter o volume total estimado do talhão.

O volume total real do talhão foi obtido pelo somatório do volume de todas as árvores, obtido a partir da aplicação dos polinômios de 5° grau, que conforme já apresentado foram ajustados pela empresa florestal que forneceu os dados, e utilizando sua própria base de dados. A partir do volume real total observou-se a qualidade da estimativa a partir das equações e árvores detectadas.

4.4 RESULTADOS

4.4.1 Estimativas para o talhão *Eucalyptus*

Os resultados das equações estimativas para dap no talhão *Eucalyptus*, usando-se as câmeras NIR e Multi, estão apresentados na TABELA 49. Os melhores valores de coeficiente de determinação ajustado foram encontrados nas equações 6 e 7, para ambas as câmeras, sendo essas as equações que utilizam as variáveis de texturas espectrais e estruturais (equação 6), e todas as variáveis (equação 7), respectivamente. A melhor equação no geral foi a 7 com a câmera NIR, com $R^2_{aj.}$ de 0,58 e 0,56, e $Syx\%$ de 8,98% e 8,44%, para os dados de treino e validação, respectivamente. As variáveis derivadas dos dados estruturais e espectrais originais (sem cálculo das texturas GLCM) apresentaram os piores resultados em ambos os

casos, e a combinação de mais de um tipo de variável se mostrou melhor do que apenas um. Na TABELA 50 estão apresentadas as duas melhores equações para as duas câmeras.

TABELA 49 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO *EUCALYPTUS*

Câmera	N	Variáveis	Treino				Validação		
			R ² aj.	Syx %	Nota	F calc.	F tab. 1%.	R ² aj.	Syx %
NIR	1	Estrutural	0,35	11,15	12	162,13**	3,03	0,36	10,14
	2	Espectral	0,34	11,22	14	112,00**	2,65	0,27	10,89
	3	Textura espectral	0,41	10,61	8	96,17**	2,26	0,36	10,18
	4	Textura estrutural	0,38	10,86	10	155,85**	2,81	0,38	10,04
	5	Estrutural + espectral	0,51	9,72	6	170,84**	2,42	0,49	9,12
	6	Text. estrutural + text. espectral	0,56	9,20	4	135,29**	2,09	0,53	8,72
	7	Todas	0,58	8,98	2	128,95**	2,01	0,56	8,44
Multi	1	Estrutural	0,31	11,50	12	134,90**	3,03	0,31	10,56
	2	Espectral	0,27	11,81	14	51,88**	2,26	0,11	11,99
	3	Textura espectral	0,37	11,02	10	62,56**	2,09	0,22	11,26
	4	Textura estrutural	0,40	10,71	8	72,29**	2,09	0,35	10,22
	5	Estrutural + espectral	0,43	10,49	6	79,84**	2,09	0,36	10,21
	6	Text. estrutural + text. espectral	0,51	9,73	4	77,33**	1,89	0,45	9,43
	7	Todas	0,57	9,05	2	87,50**	1,82	0,51	8,92

Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi <0,0001, enquanto que o p-valor de todas as variáveis <0,05.

FONTE: A autora (2018).

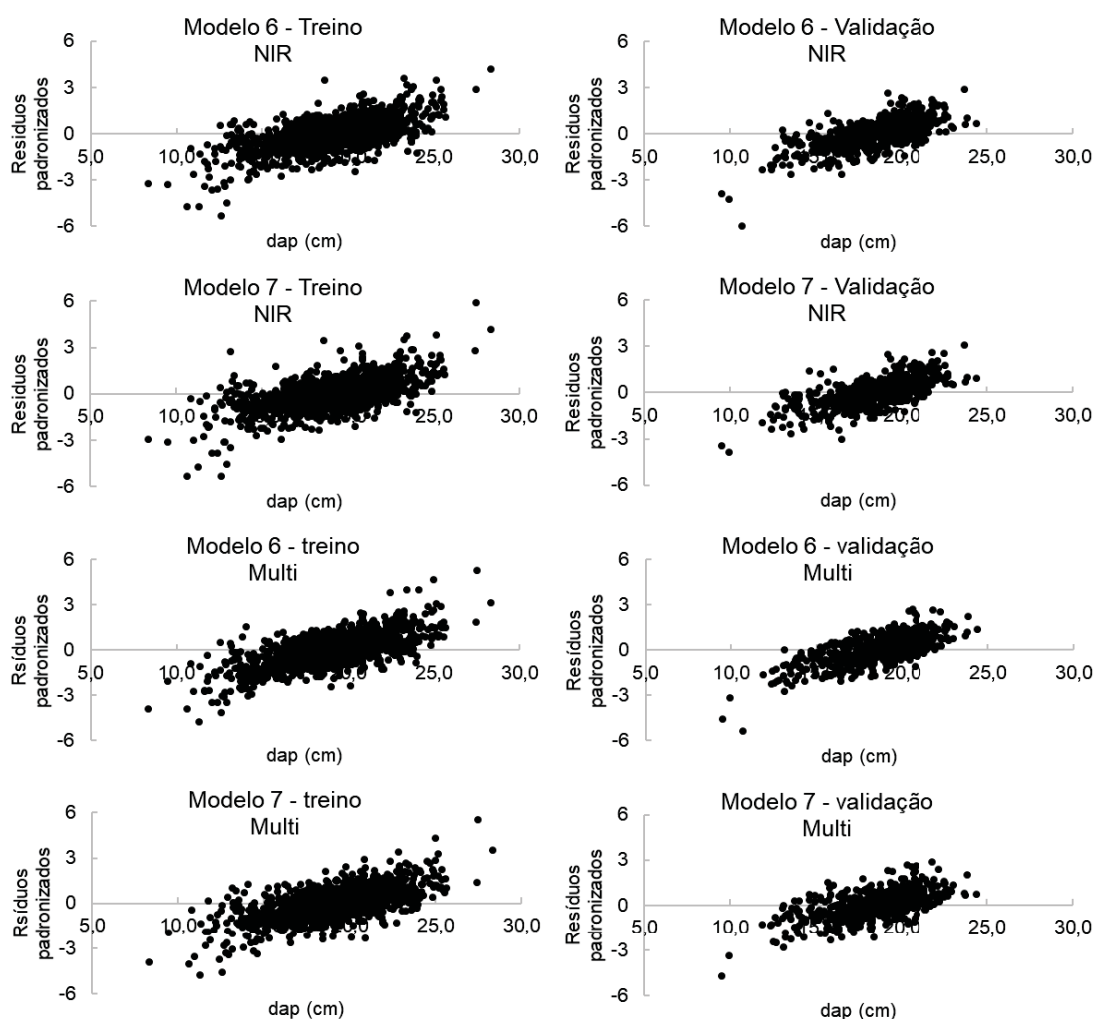
TABELA 50 – MELHORES EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO *EUCALYPTUS*

Câmera	N	Equação
NIR	6	dap = 6,70785 + 0,000937123*CHM_var_sum + 0,0773001*CHM_var_stdv + 3,34378*MDS_hom_med + 9,21703*MDS_hom_stdv + 5,97965*MDS_ent_stdv - 12,5605*MDS_2m_stdv + 0,0208203*Red_var_stdv - 0,0383334*Red_dis_sum + 0,0594353*Gre_var_med + 1,06111*Gre_dis_stdv - 0,0154639*NIR_var_med - 5,14108*NIR_hom_stdv - 0,134404*NIR_con_med + 1,60144*NIR_dis_stdv
	7	dap = 0,0265935*CHM_sum - 0,176328*Red_med + 0,262319*Red_stdv + 0,284012*Gre_med - 0,305194*Gre_stdv + 0,0719638*CHM_var_stdv - 1,4155*CHM_hom_max + 3,15579*MDS_hom_med + 8,33885*MDS_hom_stdv + 7,0208*MDS_ent_stdv - 14,1481*MDS_2m_stdv + 0,351459*Red_2m_sum + 0,04319*Gre_var_stdv - 0,000388074*NIR_var_sum - 4,27445*NIR_hom_med - 0,0674001*NIR_dis_sum + 1,54153*NIR_dis_stdv
Multi	6	dap = 0,198227*Gre_var_stdv - 0,250491*Gre_con_sum + 5,22769*Gre_con_med - 2,41535*Gre_2m_stdv - 1,83654*Red_2m_med + 0,156543*RE_hom_sum - 0,32999*RE_con_med + 0,152379*RE_con_stdv - 0,100501*RE_ent_sum + 0,0095441*NIR_var_med + 0,241198*NIR_con_med + 0,0420527*CHM_var_med + 0,0460686*CHM_var_stdv - 0,0198415*CHM_var_max - 2,02099*CHM_hom_max + 0,196782*CHM_dis_max + 0,0159936*MDS_var_med - 0,0171065*MDS_var_max + 0,226528*MDS_ent_sum + 4,90619*MDS_ent_med + 0,592403*MDS_2m_sum
	7	dap = -25,036 - 220,52*Gre_stdv - 124,555*RE_stdv + 3,49286*NIR_sum + 49,8933*NDRE_med - 19,3185*NDRE_stdv + 0,251878*Gre_var_stdv - 1,65725*Red_2m_med + 0,0444294*RE_var_med + 0,0932284*RE_var_stdv - 1,67982*RE_dis_med - 0,089896*RE_ent_sum - 0,00464724*NIR_var_sum + 0,211438*NIR_con_med + 0,000814782*CHM_var_sum + 0,0181904*CHM_var_stdv + 0,215691*CHM_dis_max + 0,0137037*MDS_var_med - 0,0144783*MDS_var_max + 10,2037*MDS_hom_med - 0,0166182*MDS_con_sum + 5,84397*MDS_dis_med + 9,6179*MDS_ent_med + 13,6789*MDS_2m_med

FONTE: A autora (2018).

Na FIGURA 36 estão apresentados os resíduos padronizados para as melhores equações, 6 e 7, para ambos dados de treino e validação. É possível verificar que existe tendência de superestimativa do dap das menores árvores (em dap), e subestimativa do dap das maiores árvores.

FIGURA 36 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE DAP NO TALHÃO *EUCALYPTUS*, PARA DADOS DE TREINO E VALIDAÇÃO



FONTE: A autora (2018).

As estatísticas de ajuste das equações para estimativa de alturas no talhão *Eucalyptus* estão apresentadas na TABELA 51. Da mesma forma que ocorreu para a estimativa de dap, as duas melhores equações são também as de número 6 (variáveis de textura espectral e textura estrutural) e 7 (todas as variáveis), tanto para a câmera NIR como Multi.

No caso das estimativas de altura, os valores de $R^2_{aj.}$ foram menores do que na estimativa de dap, atingindo um máximo e 0,48 e 0,50 com a câmera NIR, e 0,52

e 0,45 para a banda Multi, para treino e validação respectivamente. Já os valores de erro são menores em todos os casos, apresentando 6,20% e 5,53% para a câmera NIR e 5,94% e 5,78% para a câmera Multi, para os dados de treino e validação, respectivamente, com a equação 7.

TABELA 51 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO *EUCALYPTUS*

Câmera	N	Variáveis	Treino				Validação	
			R ² aj.	Syx %	Nota	F calc.	F tab. 1%.	R ² aj. Syx %
NIR	1	Estrutural	0,41	6,60	8	254,84**	3,33	0,42 5,97
	2	Espectral	0,15	7,89	14	66,73**	3,33	0,15 7,20
	3	Textura espectral	0,22	7,58	12	35,10**	2,20	0,18 7,08
	4	Textura estrutural	0,39	6,67	10	193,66**	3,03	0,40 6,09
	5	Estrutural + espectral	0,45	6,37	6	133,66**	2,42	0,47 5,70
	6	Text. estrutural + text. espectral	0,45	6,35	4	87,57**	2,09	0,43 5,89
	7	Todas	0,48	6,20	2	123,20**	2,26	0,50 5,53
Multi	1	Estrutural	0,38	6,72	10	233,21**	3,33	0,33 6,40
	2	Espectral	0,22	7,55	12	54,17**	2,52	0,16 7,16
	3	Textura espectral	0,21	7,59	14	51,65**	2,52	0,11 7,38
	4	Textura estrutural	0,43	6,49	8	74,34**	2,05	0,33 6,39
	5	Estrutural + espectral	0,45	6,34	6	137,20**	2,42	0,39 6,12
	6	Text. estrutural + text. espectral	0,47	6,24	4	73,67**	1,95	0,37 6,23
	7	Todas	0,52	5,94	2	64,91**	1,79	0,45 5,78

Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi <0,0001, enquanto que o p-valor de todas as variáveis <0,05.

FONTE: A autora (2018).

Nas estimativas de altura com base nas variáveis espectrais e em texturas derivadas de dados espectrais, de forma individualizada, foram obtidos os piores resultados. O uso das variáveis estruturais de forma única apresentou um R²aj. próximo ao das melhores equações, explicando 41% e 38% da variabilidade dos dados, para as câmeras NIR e Multi, respectivamente. As equações com os melhores desempenhos para as câmeras NIR e Multi estão apresentados na TABELA 52. Observa-se que, apesar de existir um grande número de variáveis relacionadas à estrutura da floresta (CHM, MDS), as variáveis relativas a valores espectrais e suas derivadas texturais também são selecionadas.

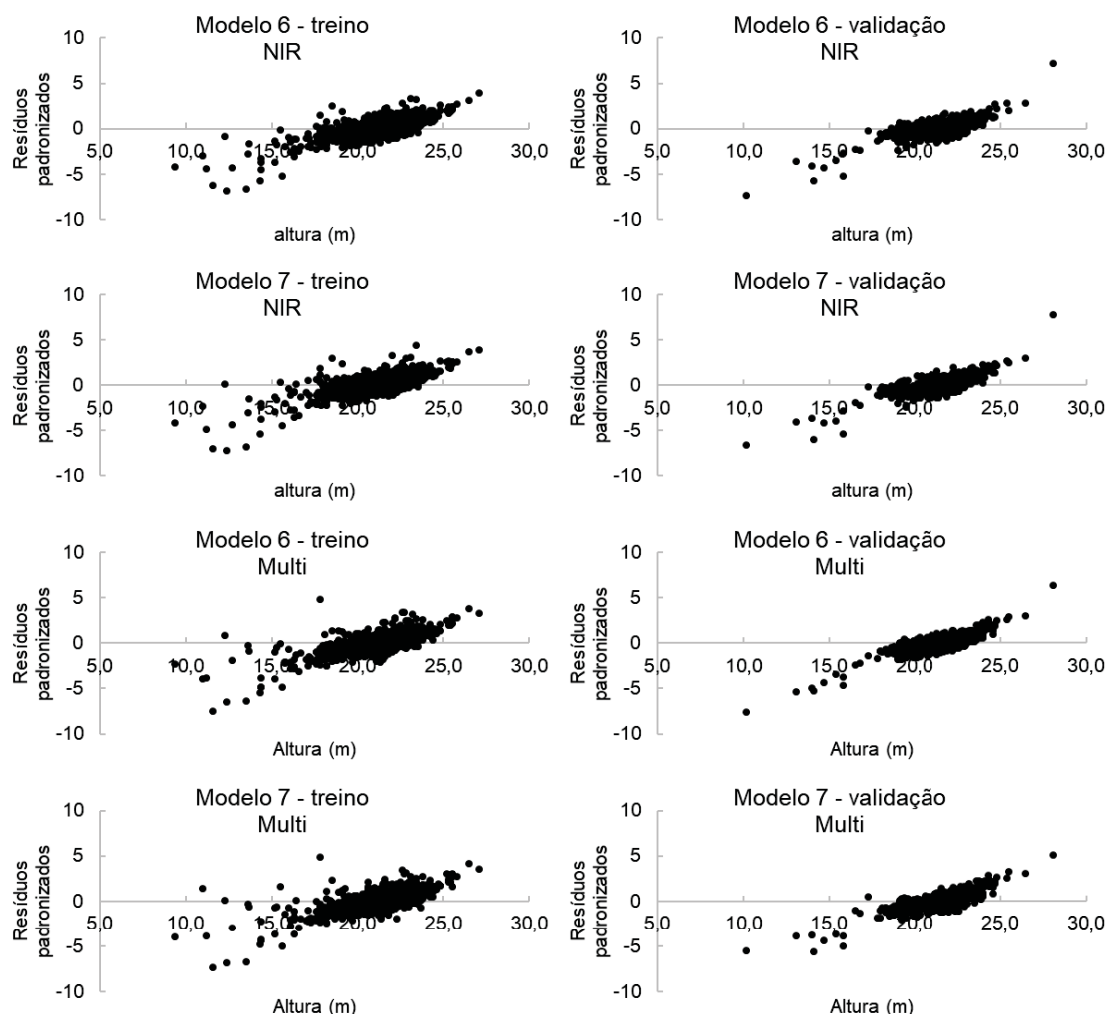
Os resíduos padronizados das equações com melhor desempenho, 6 e 7, para as câmeras NIR e Multi, estão apresentados na FIGURA 37. Assim, como encontrado para as estimativas de dap, observa-se tendência de superestimava da altura das árvores mais baixas e subestimativa das árvores mais altas. Observa-se, também, a presença de algumas árvores com valores de erro muito superior aos demais, em geral quebradas, dominadas ou rebrotas.

TABELA 52 – MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO *EUCALYPTUS*

Câmera	N	Equações
NIR	6	Altura = $9,42237 + 0,0404151 \cdot \text{CHM_var_med} + 0,0492106 \cdot \text{CHM_var_stdv} - 0,0148105 \cdot \text{CHM_var_max} + 0,0175483 \cdot \text{MDS_var_med} - 0,0164722 \cdot \text{MDS_var_max} + 0,00156709 \cdot \text{Red_var_sum} - 0,0723295 \cdot \text{Red_var_stdv} - 0,0474063 \cdot \text{Red_dis_sum} - 0,00249493 \cdot \text{Gre_var_sum} + 0,0896354 \cdot \text{Gre_var_stdv} + 0,0027205 \cdot \text{Gre_con_sum} + 0,6049 \cdot \text{Gre_dis_stdv} + 0,00044246 \cdot \text{NIR_var_sum} - 0,0823441 \cdot \text{NIR_hom_sum}$
	7	Altura = $-11,3438 + 0,984807 \cdot \text{CHM_med} - 0,258933 \cdot \text{CHM_max} - 0,234604 \cdot \text{MDS_stdv} + 0,0573273 \cdot \text{NIR_med} + 0,0308578 \cdot \text{NIR_stdv} + 0,0993571 \cdot \text{Intens_med} + 0,0373307 \cdot \text{CHM_var_stdv} + 0,0000206742 \cdot \text{MDS_var_sum} + 1,35331 \cdot \text{MDS_hom_med} + 0,0872956 \cdot \text{Red_hom_sum} - 0,0535153 \cdot \text{Gre_var_med}$
Multi	6	Altura = $16,2768 - 0,00451883 \cdot \text{Gre_var_sum} + 0,149944 \cdot \text{Gre_var_stdv} - 0,532576 \cdot \text{Gre_con_med} + 0,000349808 \cdot \text{RE_var_sum} - 0,00497514 \cdot \text{RE_con_sum} + 0,565407 \cdot \text{NIR_dis_med} - 1,12396 \cdot \text{NIR_ent_med} + 0,0307183 \cdot \text{CHM_var_med} + 0,0376857 \cdot \text{CHM_var_stdv} - 0,0127934 \cdot \text{CHM_var_max} - 5,38595 \cdot \text{CHM_hom_med} + 0,130685 \cdot \text{CHM_con_med} + 0,171839 \cdot \text{CHM_dis_sum} - 6,49394 \cdot \text{CHM_dis_med} - 0,00798571 \cdot \text{MDS_var_stdv} + 4,36889 \cdot \text{MDS_hom_max} - 0,0221982 \cdot \text{MDS_con_sum} + 0,541287 \cdot \text{MDS_con_med}$
	7	Altura = $-273,992 + 0,417282 \cdot \text{MDS_med} - 0,19706 \cdot \text{MDS_max} + 10,0039 \cdot \text{Red_sum} - 28,1304 \cdot \text{RE_stdv} + 73,9966 \cdot \text{NDVI_med} + 28,6701 \cdot \text{NDVI_stdev} - 23,8558 \cdot \text{NDRE_stdv} + 0,0845209 \cdot \text{Gre_var_stdv} - 0,282751 \cdot \text{Gre_con_sum} + 6,22704 \cdot \text{Gre_con_mean} + 0,776123 \cdot \text{Gre_ent_med} + 0,202382 \cdot \text{Red_var_med} - 0,779269 \cdot \text{Red_ent_stdv} + 0,0307114 \cdot \text{RE_var_stdv} + 0,298102 \cdot \text{RE_2m_sum} - 0,000869176 \cdot \text{NIR_var_sum} - 0,533633 \cdot \text{NIR_dis_stdv} + 0,414006 \cdot \text{NIR_2m_sum} - 8,99207 \cdot \text{NIR_2m_stdv} + 0,0173174 \cdot \text{CHM_var_med} + 0,0117226 \cdot \text{CHM_var_stdv} + 0,0169389 \cdot \text{CHM_con_med} + 0,000218426 \cdot \text{MDS_var_sum} - 0,0115432 \cdot \text{MDS_var_med} + 4,47219 \cdot \text{MDS_hom_max}$

FONTE: A autora (2018).

FIGURA 37 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA NO TALHÃO *EUCALYPTUS*, PARA DADOS DE TREINO E VALIDAÇÃO



FONTE: A autora (2018).

Na TABELA 53 estão apresentados os resumos estatísticos das equações estimativas do volume para o talhão *Eucalyptus*, com as câmeras NIR e Multi. Assim, como observado para altura e dap, em ambas as câmeras, a melhor equação foi a que incluiu todas as variáveis.

O ajuste das equações de volume apresentou melhores resultados se comparados com as de altura, com R^2_{aj} similares aos observado para a estimativa de dap, com 0,59 e 0,60 para câmera NIR, e 0,56 e 0,49 para câmera Multi, para treino e validação, respectivamente com as equações 7. Os valores de erro, por outro lado, são superiores aos observados nas estimativas de dap e altura, com melhores valores de Syx% de 18,57% e 16,97% para câmera NIR e 19,40% e 19,21% para a câmera Multi, respectivamente para treino e validação. As duas melhores equações para cada câmera estão apresentadas na TABELA 54. Observa-se a seleção de variáveis de diversos tipos, incluindo espectrais, estruturais e texturas derivadas de ambas.

TABELA 53 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO *EUCALYPTUS*

Câmera	N	Variáveis	Treino				Validação	
			R ² aj.	Syx %	Nota	F calc.	F tab. 1%.	R ² aj. Syx %
NIR	1	Estrutural	0,40	22,54	10	249,64**	3,33	0,45 19,95
	2	Espectral	0,28	24,70	14	116,96**	3,03	0,27 23,07
	3	Textura espectral	0,36	23,37	12	92,22**	2,42	0,35 21,67
	4	Textura estrutural	0,44	21,76	8	107,68**	2,26	0,46 19,80
	5	Estrutural + espectral	0,51	20,42	6	256,72**	2,81	0,54 18,32
	6	Text. estrutural + text. espectral	0,57	19,16	4	163,11**	2,20	0,60 17,02
	7	Todas	0,59	18,57	2	115,04**	1,92	0,60 16,97
Multi	1	Estrutural	0,37	23,07	10	148,02**	2,81	0,40 20,87
	2	Espectral	0,25	25,30	14	49,35**	2,33	0,11 25,41
	3	Textura espectral	0,33	23,86	12	61,67**	2,20	0,20 24,16
	4	Textura estrutural	0,42	22,14	8	99,59**	2,26	0,42 20,54
	5	Estrutural + espectral	0,43	21,99	6	102,66**	2,26	0,40 20,83
	6	Text. estrutural + text. espectral	0,52	20,10	4	78,77**	1,87	0,49 19,27
	7	Todas	0,56	19,40	2	72,55**	1,77	0,49 19,21

Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi <0,0001, enquanto que o p-valor de todas as variáveis <0,05.

FONTE: A autora (2018).

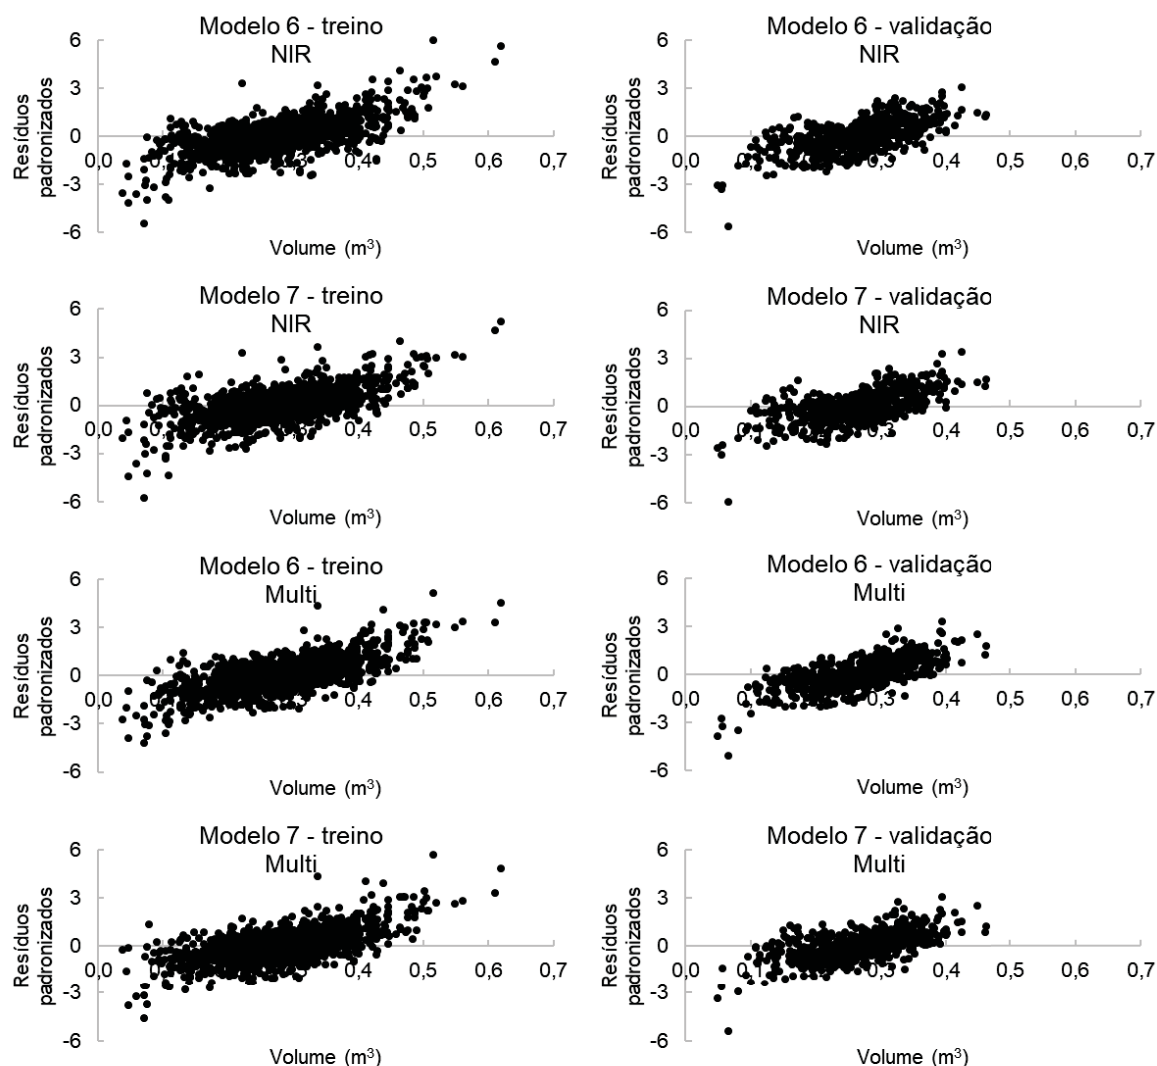
TABELA 54 - MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO *EUCALYPTUS*

Câmera	N	Equações
NIR	6	Vol = 0,0000397978*CHM_var_sum + 0,00233385*CHM_var_stdv + 7,83771E-7*MDS_var_sum - 0,00016291*MDS_con_sum + 0,0153908*MDS_dis_max + 0,110119*MDS_ent_stdv - 0,227124*MDS_2m_stdv + 0,000531209*Red_var_stdv - 0,00464335*Red_hom_sum - 0,00280195*Red_dis_sum + 0,0000553081*Gre_var_sum + 0,0614488*Gre_dis_stdv - 0,0000152825*NIR_var_sum
	7	Vol = -0,592952 + 0,0288488*CHM_med - 0,0732218*Red_stdv + 0,000136277*Gre_sum - 0,30652*Gre_stdv - 0,0314831*NIR_stdv + 0,414612*Intens_stdv + 0,00260951*CHM_var_stdv - 0,000115041*CHM_con_sum + 0,0050924*MDS_hom_sum + 0,242869*MDS_hom_stdv + 0,00969536*MDS_dis_max + 0,201144*MDS_ent_stdv - 0,447105*MDS_2m_stdv - 0,00161156*Red_dis_sum + 0,0102618*Red_2m_sum + 0,00111003*Gre_var_stdv - 0,0000167989*NIR_var_sum - 0,125933*NIR_hom_stdv + 0,045927*NIR_dis_stdv
Multi	6	Vol = 0,00562688*Gre_var_stdv - 0,00805699*Gre_con_sum + 0,163096*Gre_con_med - 0,0891763*Gre_2m_stdv - 0,0472926*Red_2m_med + 0,00552608*RE_hom_sum - 0,00753275*RE_con_med + 0,00357029*RE_con_stdv + 0,217784*RE_ent_stdv + 0,0297246*RE_2m_sum - 1,26888*RE_2m_stdv + 0,00000690569*NIR_var_sum + 0,00584212*NIR_con_med + 0,00145435*CHM_var_med + 0,00168464*CHM_var_stdv - 0,000642558*CHM_var_max - 0,0710858*CHM_hom_max - 0,00125794*CHM_con_stdv + 0,0114839*CHM_dis_max + 0,00000681429*MDS_var_sum - 0,000204436*MDS_var_max - 0,150919*MDS_hom_med
	7	Vol = -1,93991 + 0,379346*Red_sum - 4,54251*RE_stdv + 0,0501578*NIR_sum + 1,72458*NDVI_med + 0,833781*NDVI_stdv + 0,577348*NDRE_med - 0,727431*NDRE_stdv + 0,00564858*Gre_var_stdv - 0,00083365*Gre_con_sum + 0,0181135*Red_ent_med + 0,00306598*RE_var_stdv + 0,00859572*RE_con_med - 0,0673651*RE_dis_med - 0,00328461*RE_ent_sum - 0,0000702187*NIR_var_sum + 0,0000299874*CHM_var_sum + 0,000548174*CHM_var_stdv - 0,0434434*CHM_hom_max + 0,00546671*CHM_dis_max + 0,000399546*MDS_var_mean - 0,000413369*MDS_var_max - 0,000569553*MDS_con_sum + 0,0137978*MDS_con_med + 0,256718*MDS_ent_med - 0,00715014*MDS_2m_sum + 0,534949*MDS_2m_med

FONTE: A autora (2018).

Os resíduos dessas equações estão apresentados na FIGURA 38. Novamente, verifica-se a tendência de superestimativa nas menores árvores, e subestimativa nas maiores. Novamente, os valores de erro mais extremos são referentes a árvores dominadas e rebrotas, com volume muito abaixo da média.

FIGURA 38 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME NO TALHÃO *EUCALYPTUS*, PARA DADOS DE TREINO E VALIDAÇÃO



FONTE: A autora (2018).

4.4.2 Estimativas para o talhão *Pinus* 1

As equações geradas para as estimativas de dap para o talhão *Pinus* 1 (16 anos de idade), estão apresentadas na TABELA 55. O melhor resultado foi observado na equação 7 com a câmera Multi, de 0,27 e 0,29 para treino e validação, respectivamente. As demais equações apresentaram valores de R^2_{aj} variando entre

0,19 e 0,27, exceto para o uso de variáveis espectrais e texturas espectrais da câmera RGB, que apresentaram valores inferiores. Os valores de erro foram superiores a 16%, sendo o melhor valor observado de 16,41% e 16,60%, para treino e validação respectivamente, com a equação 7 da câmera Multi.

Observa-se que os melhores resultados foram encontrados, de maneira geral, com a câmera Multi, seguido pela câmera NIR e os piores resultados foram obtidos com a câmera RGB. A câmera RGB ainda apresentou a mesma equação, tanto para os cenários 6 e 7, de forma que, mesmo quando todas as variáveis estavam disponíveis, o processo *stepwise* somente selecionou variáveis de textura estrutural ou espectral.

TABELA 55 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO PINUS 1

Câmera	N	Variáveis	Treino				Validação		
			R ² aj.	Syx %	Nota	F calc.	F tab. 1%.	R ² aj.	Syx %
RGB	1	Estrutural	0,20	17,22	8	232,01**	4,62	0,24	17,16
	2	Espectral	0,14	17,77	10	80,40**	3,33	0,20	17,60
	3	Textura espectral	0,14	17,81	12	62,73**	3,03	0,19	17,67
	4	Textura estrutural	0,20	17,21	6	233,77**	4,62	0,22	17,37
	5	Estrutural + espectral	0,22	16,97	4	134,18**	3,33	0,28	16,66
	6	Text. estrutural + text. espectral	0,23	16,85	2	81,88**	2,65	0,26	16,94
	7	Todas	0,23	16,85	2	81,88**	2,65	0,26	16,95
NIR	1	Estrutural	0,22	16,97	8	133,77**	3,33	0,26	16,95
	2	Espectral	0,19	17,25	14	152,49**	3,79	0,23	17,30
	3	Textura espectral	0,20	17,16	12	96,45**	3,03	0,22	17,32
	4	Textura estrutural	0,21	17,01	10	131,06**	3,33	0,23	17,27
	5	Estrutural + espectral	0,23	16,82	6	289,10**	4,62	0,28	16,73
	6	Text. estrutural + text. espectral	0,23	16,81	4	145,56**	3,33	0,24	17,11
	7	Todas	0,24	16,74	2	100,89**	2,81	0,25	17,04
Multi	1	Estrutural	0,20	17,13	14	244,80**	4,62	0,24	17,10
	2	Espectral	0,21	17,01	8	131,11**	3,33	0,24	17,19
	3	Textura espectral	0,21	17,12	12	55,47**	2,42	0,21	17,44
	4	Textura estrutural	0,21	17,04	10	257,39**	4,62	0,24	17,20
	5	Estrutural + espectral	0,27	16,45	6	115,63**	2,81	0,32	16,23
	6	Text. estrutural + text. espectral	0,27	16,45	4	87,10**	2,52	0,29	16,57
	7	Todas	0,27	16,41	2	71,09**	2,33	0,29	16,60

Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi <0,0001, enquanto que o p-valor de todas as variáveis <0,05.

FONTE: A autora (2018).

As duas melhores equações estimativas do dap para cada câmera estão apresentadas na TABELA 56. É possível ser observado que um número bastante inferior de variáveis foi selecionado em cada equação, se comparados com as equações estimativas do talhão *Eucalyptus*.

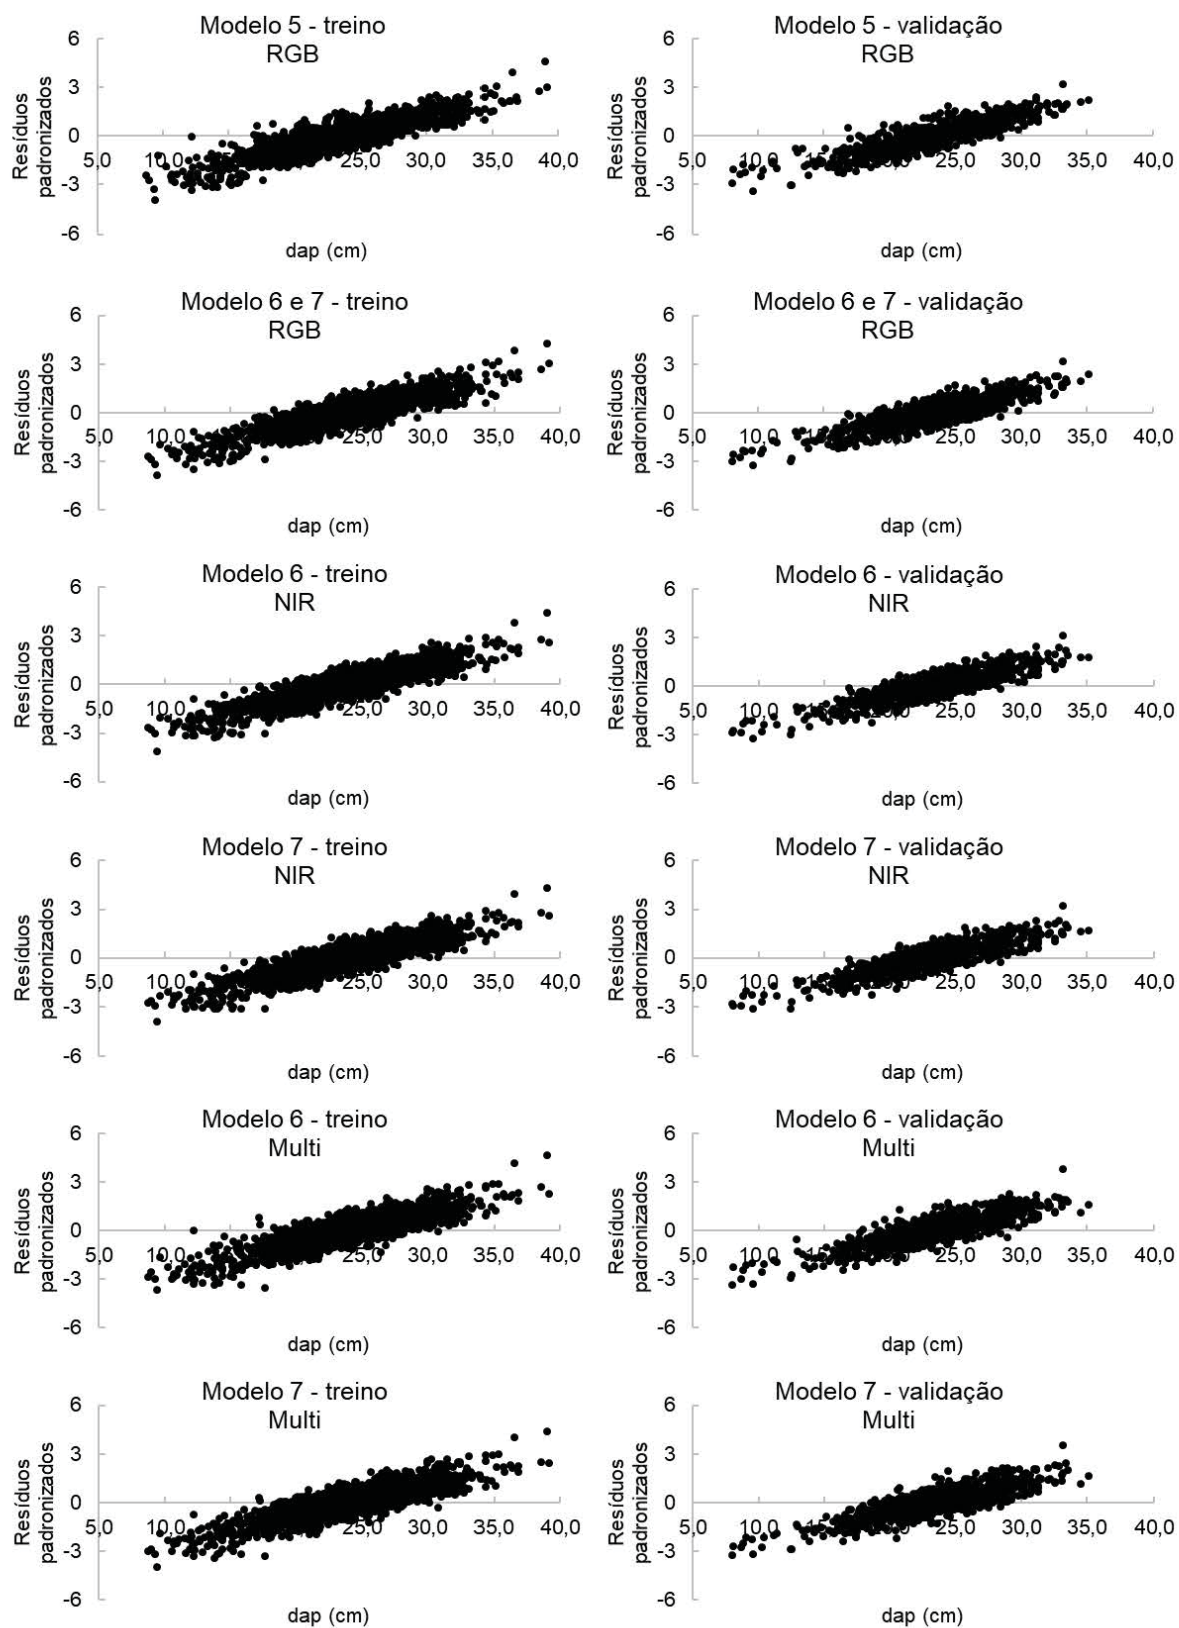
TABELA 56 - MELHORES EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO *PINUS 1*

Câmera	N	Equações
RGB	5	$dap = 0,517665 * Area + 0,993764 * CHM_med + 0,940659 * CHM_stdv + 0,000900453 * Blue_sum - 0,0679397 * Blue_stdv$
	6 e 7	$dap = 19,9465 + 0,00101015 * CHM_var_sum - 0,0636322 * CHM_2m_sum + 0,000810428 * Red_var_sum + 7,20987 * Red_ent_med - 0,000518431 * Gre_var_sum - 0,00107676 * Gre_con_sum - 9,21544 * Blue_ent_med$
NIR	6	$dap = 19,7923 + 0,00161429 * CHM_var_sum + 0,0387498 * MDS_ent_sum + 0,0137647 * Red_var_med - 2,79631 * Gre_ent_med$
	7	$dap = 23,8119 + 0,0387574 * Red_med + 0,00166106 * CHM_var_sum - 0,149188 * CHM_var_stdv - 3,08179 * CHM_2m_med + 0,0384964 * MDS_ent_sum - 4,19845 * Gre_ent_med$
Multi	6	$dap = 20,9153 + 0,0670325 * CHM_var_med - 0,0359799 * CHM_var_max - 5,3057 * CHM_2m_med + 0,0012955 * Gre_var_sum + 0,444801 * Gre_hom_sum - 21,7531 * Gre_hom_med - 0,00802359 * Gre_con_sum - 0,038422 * NIR_var_stdv$
	7	$dap = 6,05528 - 1,26007 * CHM_stdv + 282,227 * Red_med - 21,7571 * NIR_stdv - 25,6758 * NDRE_stdv - 0,00947974 * Gre_con_sum + 1,42896 * Gre_dis_med - 12,8158 * NIR_2m_stdv + 0,000688699 * CHM_var_sum + 5,07833 * CHM_hom_max + 0,0802525 * CHM_ent_sum$

FONTE: A autora (2018).

Por fim, os resíduos das melhores equações estimativas de dap, para as câmeras RGB, NIR e Multi, relativos aos dados de treino e validação, estão apresentados na FIGURA 39. Observa-se novamente a superestimativa dos valores de dap nas menores árvores, e subestimativa nas maiores.

FIGURA 39 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE DAP NO TALHÃO *PINUS 1*, PARA DADOS DE TREINO E VALIDAÇÃO



FONTE: A autora (2018).

As estimativas de altura do talhão *Pinus* 1 estão apresentadas na TABELA 57. Observa-se uma melhora nas estimativas, em relação às estimativas de dap no talhão *Pinus* 1. A melhor equação estimativa foi, assim como para dap, obtida com a câmera Multi (equação 7), resultando em $R^2_{aj.}$ de 0,34 e 0,30 e erro de 13,87% e 14,92%, respectivamente, para dados de treino e validação. No caso da câmera Multi, a melhor equação encontrada foi a que utilizou todas as variáveis (equação 7), porém essa é seguida pela equação 5, que utiliza as variáveis estruturais e espectrais. Para as outras câmeras, a equação 6 (texturas espectrais e estruturais) foi ligeiramente superior à equação 5.

TABELA 57 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO *PINUS* 1

Câmera	N	Variáveis	Treino				Validação	
			$R^2_{aj.}$	Syx %	Nota	F calc.	F tab. 1%.	$R^2_{aj.}$ Syx %
RGB	1	Estrutural	0,23	15,07	10	554,70**	6,65	0,22 15,74
	2	Espectral	0,12	16,08	14	128,06**	4,62	0,14 16,49
	3	Textura espectral	0,13	15,99	12	47,63**	2,81	0,13 16,58
	4	Textura estrutural	0,24	14,92	8	76,57**	2,52	0,21 15,80
	5	Estrutural + espectral	0,29	14,41	6	131,67**	2,81	0,28 15,13
	6	Text. estrutural + text. espectral	0,29	14,39	4	99,99**	2,52	0,26 15,26
	7	Todas	0,31	14,18	2	80,24**	2,26	0,28 15,14
NIR	1	Estrutural	0,28	14,54	8	245,51**	3,79	0,25 15,44
	2	Espectral	0,19	15,41	14	64,89**	2,65	0,18 16,11
	3	Textura espectral	0,20	15,34	12	59,55**	2,52	0,17 16,21
	4	Textura estrutural	0,28	14,57	10	145,77**	3,03	0,24 15,49
	5	Estrutural + espectral	0,31	14,27	6	120,13**	2,65	0,27 15,22
	6	Text. estrutural + text. espectral	0,32	14,16	4	68,66**	2,14	0,25 15,37
	7	Todas	0,32	14,10	2	101,42**	2,42	0,26 15,28
Multi	1	Estrutural	0,26	14,72	10	169,24**	3,33	0,23 15,64
	2	Espectral	0,20	15,29	12	97,51**	3,03	0,18 16,09
	3	Textura espectral	0,15	15,74	14	70,63**	3,03	0,16 16,33
	4	Textura estrutural	0,27	14,60	8	143,69**	3,03	0,23 15,60
	5	Estrutural + espectral	0,33	14,01	4	105,18**	2,42	0,30 14,83
	6	Text. estrutural + text. espectral	0,31	14,26	6	94,38**	2,42	0,28 15,05
	7	Todas	0,34	13,87	2	83,89**	2,19	0,30 14,92

Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi <0,0001, enquanto que o p-valor de todas as variáveis <0,05.

FONTE: A autora (2018).

As duas melhores equações estimativas de altura para as câmeras RGB, NIR e Multi estão apresentadas na TABELA 58. Novamente, observa-se que um número menor de variáveis foi selecionado, se comparado ao talhão *Eucalyptus*. Nas equações geradas para a câmera Multi, é observada a seleção de variáveis derivadas do índice de vegetação NDRE.

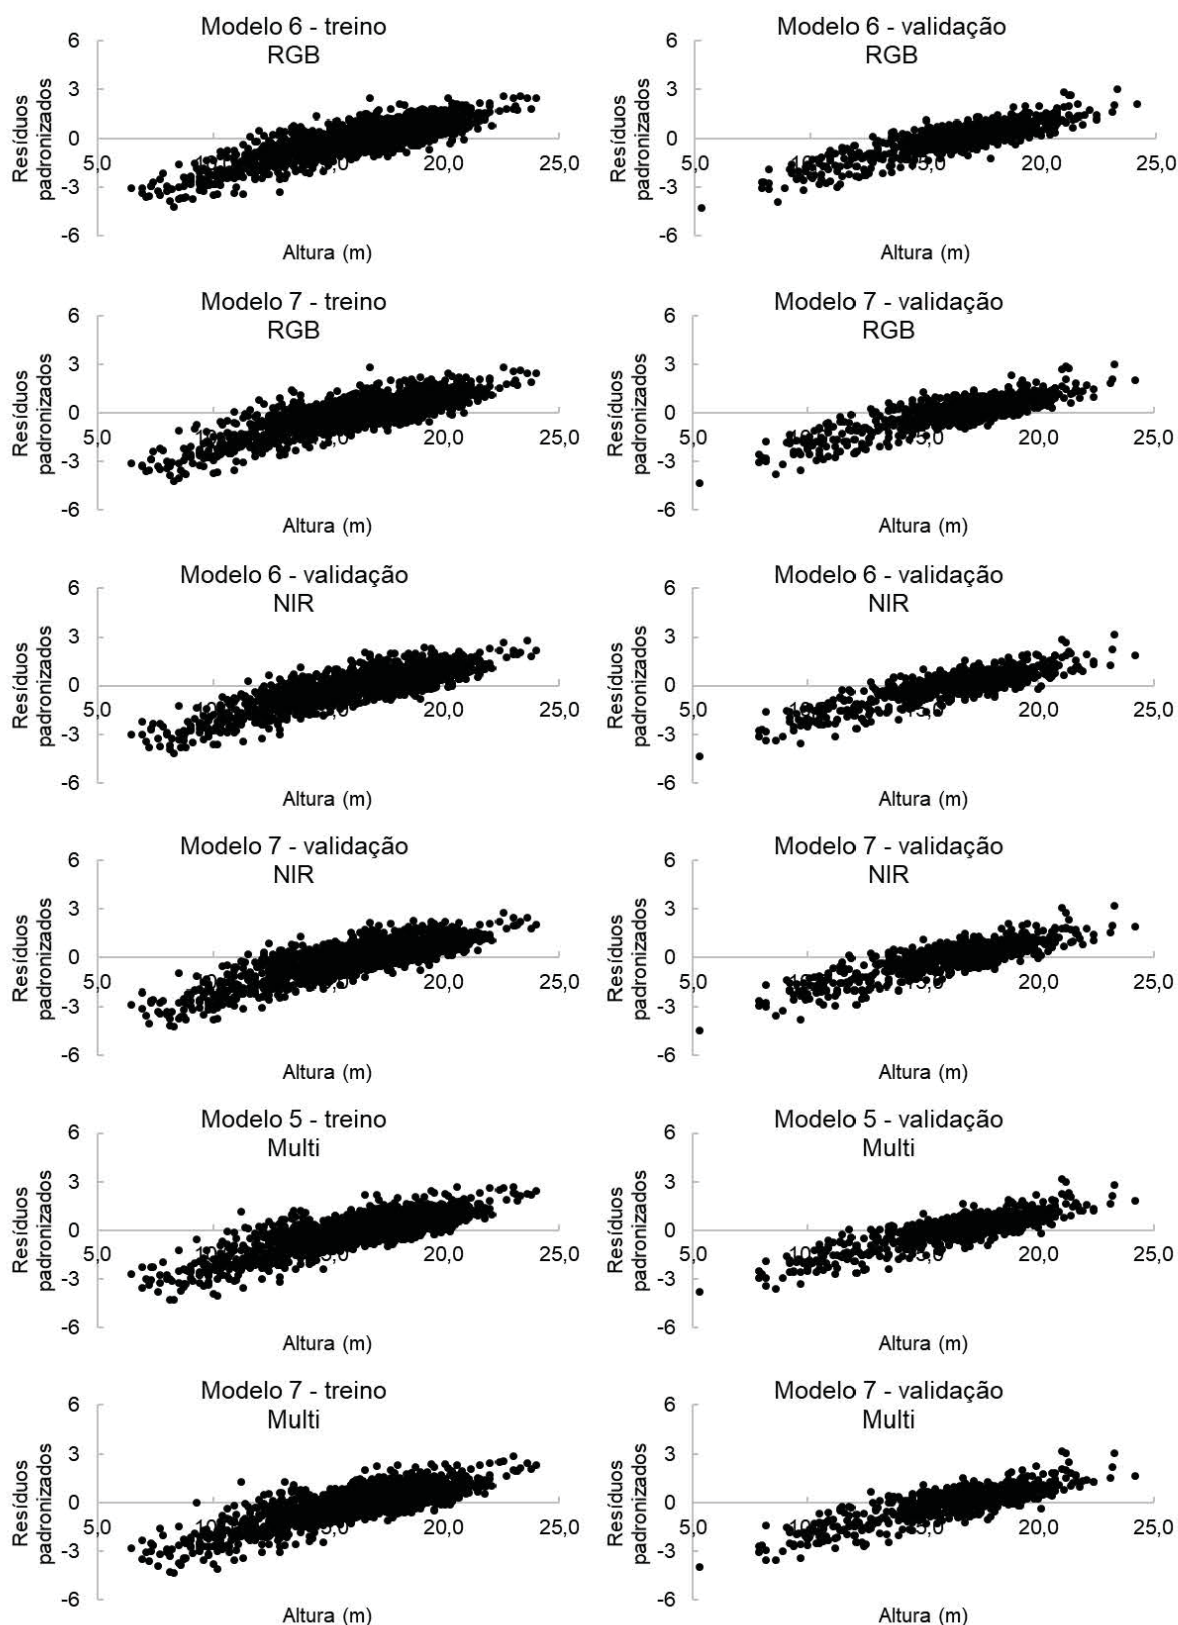
TABELA 58 - MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO *PINUS 1*

Câmera	N	Equações
RGB	6	Altura = $6,75947 + 0,0494466*CHM_var_med - 0,0159112*CHM_var_max + 0,0303523*CHM_ent_sum - 0,725176*CHM_ent_max + 0,0000500907*MDS_var_sum + 0,000230508*Red_var_sum + 0,456697*Red_dis_med - 0,00243611*Blue_con_sum$
	7	Altura = $-298,663 + 1,37488*CHM_med + 1,36524*CHM_stdv + 0,311229*MDS_med + 0,00216567*Red_sum - 0,0014652*Intens_sum - 0,0213241*CHM_var_max + 0,0377259*CHM_dis_sum - 0,843359*CHM_dis_max - 0,014741*MDS_var_max + 0,0286853*Red_con_med - 0,00187437*Blue_con_sum$
NIR	6	Altura = $2,80154 + 0,0750488*CHM_var_med + 0,000214527*MDS_var_sum + 0,0215295*MDS_var_med - 0,0262514*MDS_var_max - 3,51935*MDS_2m_stdv + 0,00169561*Red_var_sum + 7,43872*Red_hom_stdv + 20,8806*Red_2m_med - 0,00203916*Gre_var_sum + 1,19861*Gre_dis_med + 0,000225784*NIR_var_sum - 0,0904636*NIR_con_med - 0,626495*NIR_2m_sum$
	7	Altura = $-370,45 + 0,83829*CHM_med + 0,392155*MDS_med + 0,000492213*NIR_sum - 0,0203451*MDS_var_max - 2,20538*MDS_2m_max + 6,15835*Red_hom_stdv + 11,8544*Red_2m_stdv - 0,0873523*Gre_hom_sum - 17,8383*NIR_2m_stdv$
Multi	5	Altura = $-28,7099 + 0,718905*CHM_med + 1,23641*CHM_stdv + 1,17065*MDS_med - 1,13311*MDS_max - 117,755*Gre_stdv + 2,13732*Red_sum + 5,19778*NIR_med - 16,9553*NDRE_med - 31,3323*NDRE_stdv$
	7	Altura = $-179,624 + 0,788716*CHM_med + 1,14026*MDS_med - 0,944449*MDS_max + 3,33876*Red_sum - 11,9541*NDRE_med - 23,2978*NDRE_stdv - 1,01034*Gre_dis_stdv - 0,0247628*Red_ent_sum + 0,0275869*CHM_dis_sum + 0,077631*MDS_var_stdv - 0,0105978*MDS_var_max - 1,08337*MDS_con_max$

FONTE: A autora (2018).

Os resíduos das equações selecionadas, para as câmeras RGB, NIR e Multi, com os dados de treino e validação estão apresentados na FIGURA 40. Assim, como para todas as outras estimativas, observa-se tendência nos resíduos, sendo que todos superestimam os valores de altura das árvores mais baixas, e subestimam os valores das árvores mais altas.

FIGURA 40 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA NO TALHÃO *PINUS* 1, PARA DADOS DE TREINO E VALIDAÇÃO



FONTE: A autora (2018).

Por fim, o resumo estatístico das equações estimativas de volume para as árvores do talhão *Pinus* 1, está apresentado na TABELA 59. Novamente os melhores resultados são observados com a câmera Multi, resultando em valores de $R^2_{aj.}$ superiores às estimativas de dap e altura desse talhão. A melhor equação da câmera Multi apresentou $R^2_{aj.}$ de 0,37 e 0,38, e erro de 36,99% e 36,69%, para dados de treino e validação, respectivamente. Novamente, para a câmera Multi, a melhor equação encontrada foi a que utilizou todas as variáveis (equação 7), seguido pela equação 5, que se utiliza das variáveis estruturais e espectrais. Ainda, assim como para dap, no caso da câmera RGB a mesma equação foi desenvolvida quando disponíveis todas e ambas as variáveis texturais.

Apesar de melhoras nas estimativas com a câmera Multi, para as demais câmeras as equações estimativas apresentaram resultados inferiores às equações estimativas de altura. Os erros em todos os casos estão acima de 35% do volume.

TABELA 59 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO *PINUS* 1

Câmera	N	Variáveis	Treino				Validação	
			$R^2_{aj.}$	Syx %	Nota	F calc.	F tab. 1%.	$R^2_{aj.}$ Syx %
RGB	1	Estrutural	0,25	40,25	8	160,96**	3,33	0,27 39,69
	2	Espectral	0,17	42,29	10	81,20**	3,03	0,21 41,47
	3	Textura espectral	0,16	42,75	12	71,41**	3,03	0,19 41,80
	4	Textura estrutural	0,27	39,84	6	174,24**	3,33	0,28 39,56
	5	Estrutural + espectral	0,29	39,07	4	133,46**	2,81	0,32 38,29
	6	Text. estrutural + text. espectral	0,30	38,81	2	139,61**	2,81	0,32 38,53
	7	Todas	0,30	38,81	2	139,61**	2,81	0,32 38,53
NIR	1	Estrutural	0,28	39,50	10	246,71**	3,79	0,29 39,23
	2	Espectral	0,24	40,48	14	153,76**	3,33	0,26 40,13
	3	Textura espectral	0,25	40,39	12	89,96**	2,65	0,24 40,69
	4	Textura estrutural	0,28	39,37	8	189,77**	3,33	0,28 39,43
	5	Estrutural + espectral	0,31	38,77	6	280,28**	3,79	0,33 38,11
	6	Text. estrutural + text. espectral	0,31	38,56	4	124,82**	2,65	0,31 38,76
	7	Todas	0,31	38,55	2	174,64**	3,03	0,32 38,38
Multi	1	Estrutural	0,26	39,96	10	339,13**	4,62	0,27 39,81
	2	Espectral	0,26	40,10	12	165,82**	3,33	0,27 39,90
	3	Textura espectral	0,24	40,67	14	98,98**	2,81	0,25 40,43
	4	Textura estrutural	0,29	39,12	8	132,38**	2,81	0,29 39,32
	5	Estrutural + espectral	0,34	37,74	4	165,68**	2,81	0,37 37,04
	6	Text. estrutural + text. espectral	0,34	37,92	6	121,13**	2,52	0,36 37,38
	7	Todas	0,37	36,99	2	74,81**	2,05	0,38 36,69

Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi <0,0001, enquanto que o p-valor de todas as variáveis <0,05.

FONTE: A autora (2018).

As duas melhores equações estimativas de volume para o talhão *Pinus* 1, com as câmeras RGB, NIR e Multi estão apresentados na TABELA 60. Novamente, a

seleção de variáveis é menor do que observada no talhão *Eucalyptus* e, no caso da câmera Multi, é observada a seleção de variáveis relacionadas ao índice NDRE.

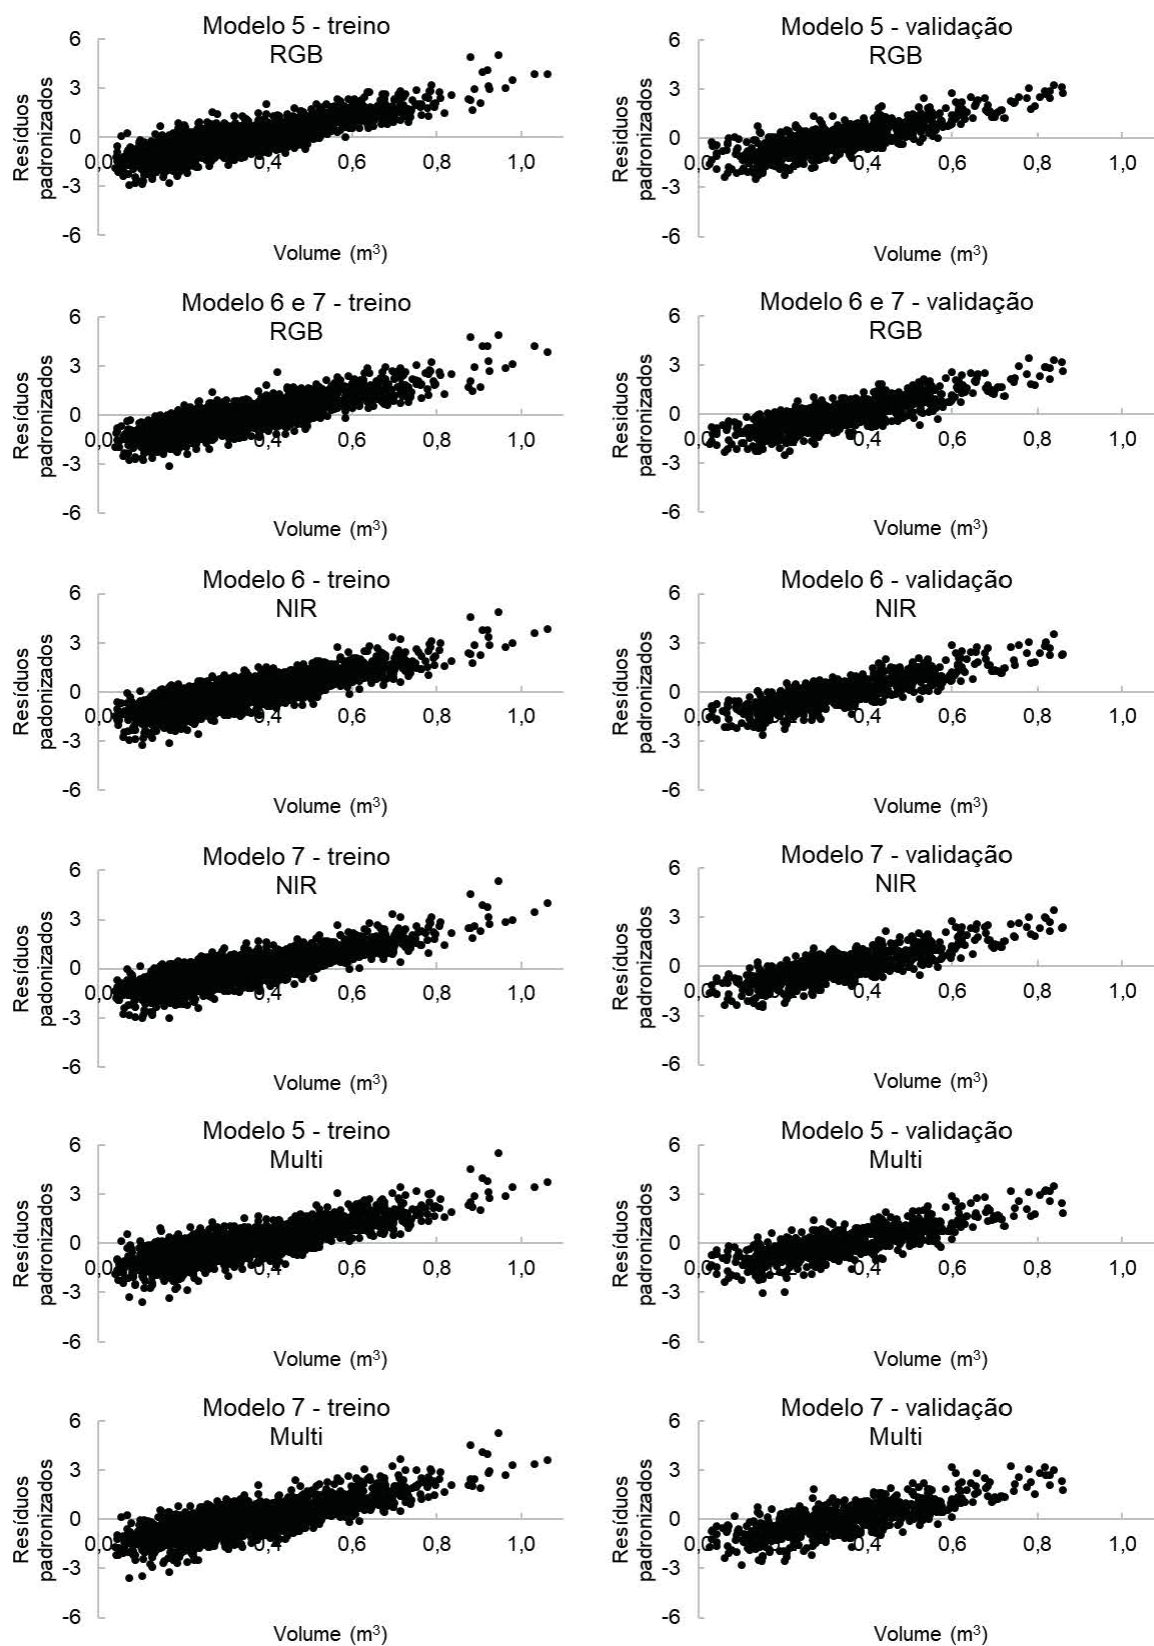
TABELA 60 - MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO *PINUS* 1

Câmera	N	Equações
RGB	5	$\text{Vol} = -0,459087 + 0,000386538 \cdot \text{CHM_sum} + 0,0303514 \cdot \text{CHM_med} + 0,0332045 \cdot \text{CHM_stdv} + 0,00556663 \cdot \text{Red_med} - 0,00400948 \cdot \text{Gre_med} - 0,00361419 \cdot \text{Blue_stdv}$
	6 e 7	$\text{Vol} = 0,000058452 \cdot \text{CHM_var_sum} - 0,000435623 \cdot \text{CHM_var_max} - 0,00373199 \cdot \text{CHM_2m_sum} + 0,00119002 \cdot \text{Red_var_med} - 0,000698648 \cdot \text{Gre_var_med} - 0,000170961 \cdot \text{Gre_con_sum} + 0,00471429 \cdot \text{Gre_con_med}$
NIR	6	$\text{Vol} = -0,0570118 + 0,0000845505 \cdot \text{CHM_var_sum} - 0,0028143 \cdot \text{CHM_hom_sum} + 0,00000227991 \cdot \text{MDS_var_sum} - 0,00178489 \cdot \text{MDS_2m_sum} + 0,00359925 \cdot \text{Red_var_med} - 0,0032807 \cdot \text{Gre_var_med} + 0,556833 \cdot \text{Gre_2m_med}$
	7	$\text{Vol} = -0,367088 + 0,00476807 \cdot \text{NIR_med} + 0,0000843179 \cdot \text{CHM_var_sum} - 0,00600238 \cdot \text{MDS_hom_sum} + 0,0174895 \cdot \text{Gre_2m_sum} - 0,000692578 \cdot \text{NIR_var_med}$
Multi	5	$\text{Vol} = -0,386347 + 0,036476 \cdot \text{CHM_med} + 0,0731628 \cdot \text{CHM_stdv} - 0,0617283 \cdot \text{MDS_stdv} - 10,6823 \cdot \text{Gre_stdv} + 0,320759 \cdot \text{Red_sum} - 1,53251 \cdot \text{NDRE_stdv}$
	7	$\text{Vol} = -1,12372 + 0,00115868 \cdot \text{MDS_med} + 10,1838 \cdot \text{Red_med} - 0,798371 \cdot \text{NIR_stdv} + 0,0750158 \cdot \text{RE_sum} + 1,52116 \cdot \text{NDVI_stdv} - 1,46162 \cdot \text{NDRE_stdv} - 0,000146237 \cdot \text{Gre_con_sum} - 0,00165796 \cdot \text{Red_ent_sum} - 0,00492238 \cdot \text{RE_var_med} - 0,209338 \cdot \text{RE_hom_med} + 0,00276086 \cdot \text{CHM_var_mean} - 0,00113396 \cdot \text{CHM_var_max} - 0,00412728 \cdot \text{CHM_2m_sum} - 0,038796 \cdot \text{MDS_con_max} - 0,00239711 \cdot \text{MDS_2m_sum}$

FONTE: A autora (2018).

Os gráficos de resíduos dessas equações, para os dados de treino e validação, estão apresentados na FIGURA 41. Mais uma vez se observa a mesma tendência de superestimativa do volume das menores árvores, e subestimativa das maiores.

FIGURA 41 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME NO TALHÃO *PINUS 1*, PARA DADOS DE TREINO E VALIDAÇÃO



FONTE: A autora (2018).

4.4.3 Estimativas para o talhão *Pinus 2*

As equações estimativas de dap para o talhão *Pinus 2* (*Pinus taeda* com 7 anos de idade), estão apresentados na TABELA 61. A equação 7, tendo como entrada todas as variáveis calculadas, apresentou o melhor resultado para as três câmeras. Já a segunda melhor equação variou entre a número 5 (combinando as variáveis estruturais e espectrais) para as câmeras RGB e NIR e a 6 (combinando as variáveis de textura derivadas dos arquivos espectrais e estruturais), para a câmera Multi.

Os melhores resultados foram encontrados com a câmera NIR seguidos pela câmera RGB, enquanto que a câmera Multi apresentou os piores resultados. A melhor equação estimativa apresentou $R^2_{aj.}$ de 0,55 e 0,48 e erro de 14,5% e 14,2%, para treino e validação, respectivamente.

TABELA 61 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO *PINUS 2*

Câmera	N	Variáveis	Treino				Validação	
			$R^2_{aj.}$	Syx %	Nota	F calc.	F tab. 1%.	$R^2_{aj.}$ Syx %
RGB	1	Estrutural	0,32	17,86	12	264,48**	3,02	0,32 16,18
	2	Espectral	0,41	16,64	8	975,42**	4,61	0,40 15,27
	3	Textura espectral	0,40	16,77	10	188,56**	2,33	0,38 15,42
	4	Textura estrutural	0,29	18,30	14	188,09**	2,81	0,29 16,53
	5	Estrutural + espectral	0,50	15,28	4	315,42**	2,41	0,46 14,44
	6	Text. estrutural + text. espectral	0,50	15,37	6	146,32**	1,91	0,46 14,50
	7	Todas	0,53	14,81	2	320,54**	2,33	0,48 14,13
NIR	1	Estrutural	0,40	16,82	10	232,56**	2,52	0,39 15,38
	2	Espectral	0,38	17,06	12	431,22**	3,33	0,36 15,74
	3	Textura espectral	0,33	17,75	14	153,88**	2,41	0,31 16,37
	4	Textura estrutural	0,41	16,61	8	180,07**	2,25	0,37 15,60
	5	Estrutural + espectral	0,50	15,30	4	354,01**	2,52	0,45 14,61
	6	Text. estrutural + text. espectral	0,49	15,54	6	177,84**	2,04	0,42 15,01
	7	Todas	0,55	14,50	2	247,90**	2,09	0,48 14,20
Multi	1	Estrutural	0,25	18,70	12	161,05**	2,81	0,26 16,95
	2	Espectral	0,23	18,97	14	123,31**	2,65	0,21 17,45
	3	Textura espectral	0,26	18,66	10	82,52**	2,19	0,21 17,51
	4	Textura estrutural	0,29	18,23	8	145,68**	2,52	0,26 16,87
	5	Estrutural + espectral	0,35	17,43	6	96,67**	2,01	0,34 16,00
	6	Text. estrutural + text. espectral	0,36	17,29	4	81,08**	1,88	0,30 16,47
	7	Todas	0,43	16,33	2	113,23**	1,91	0,39 15,41

Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi $<0,0001$, enquanto que o p-valor de todas as variáveis $<0,05$.

FONTE: A autora (2018).

As duas melhores equações com cada uma das câmeras estão apresentadas na TABELA 62. Observa-se que as equações estimativas com a câmera Multi apresentam um número bastante superior de variáveis selecionadas, se comparados as equações com as demais câmeras.

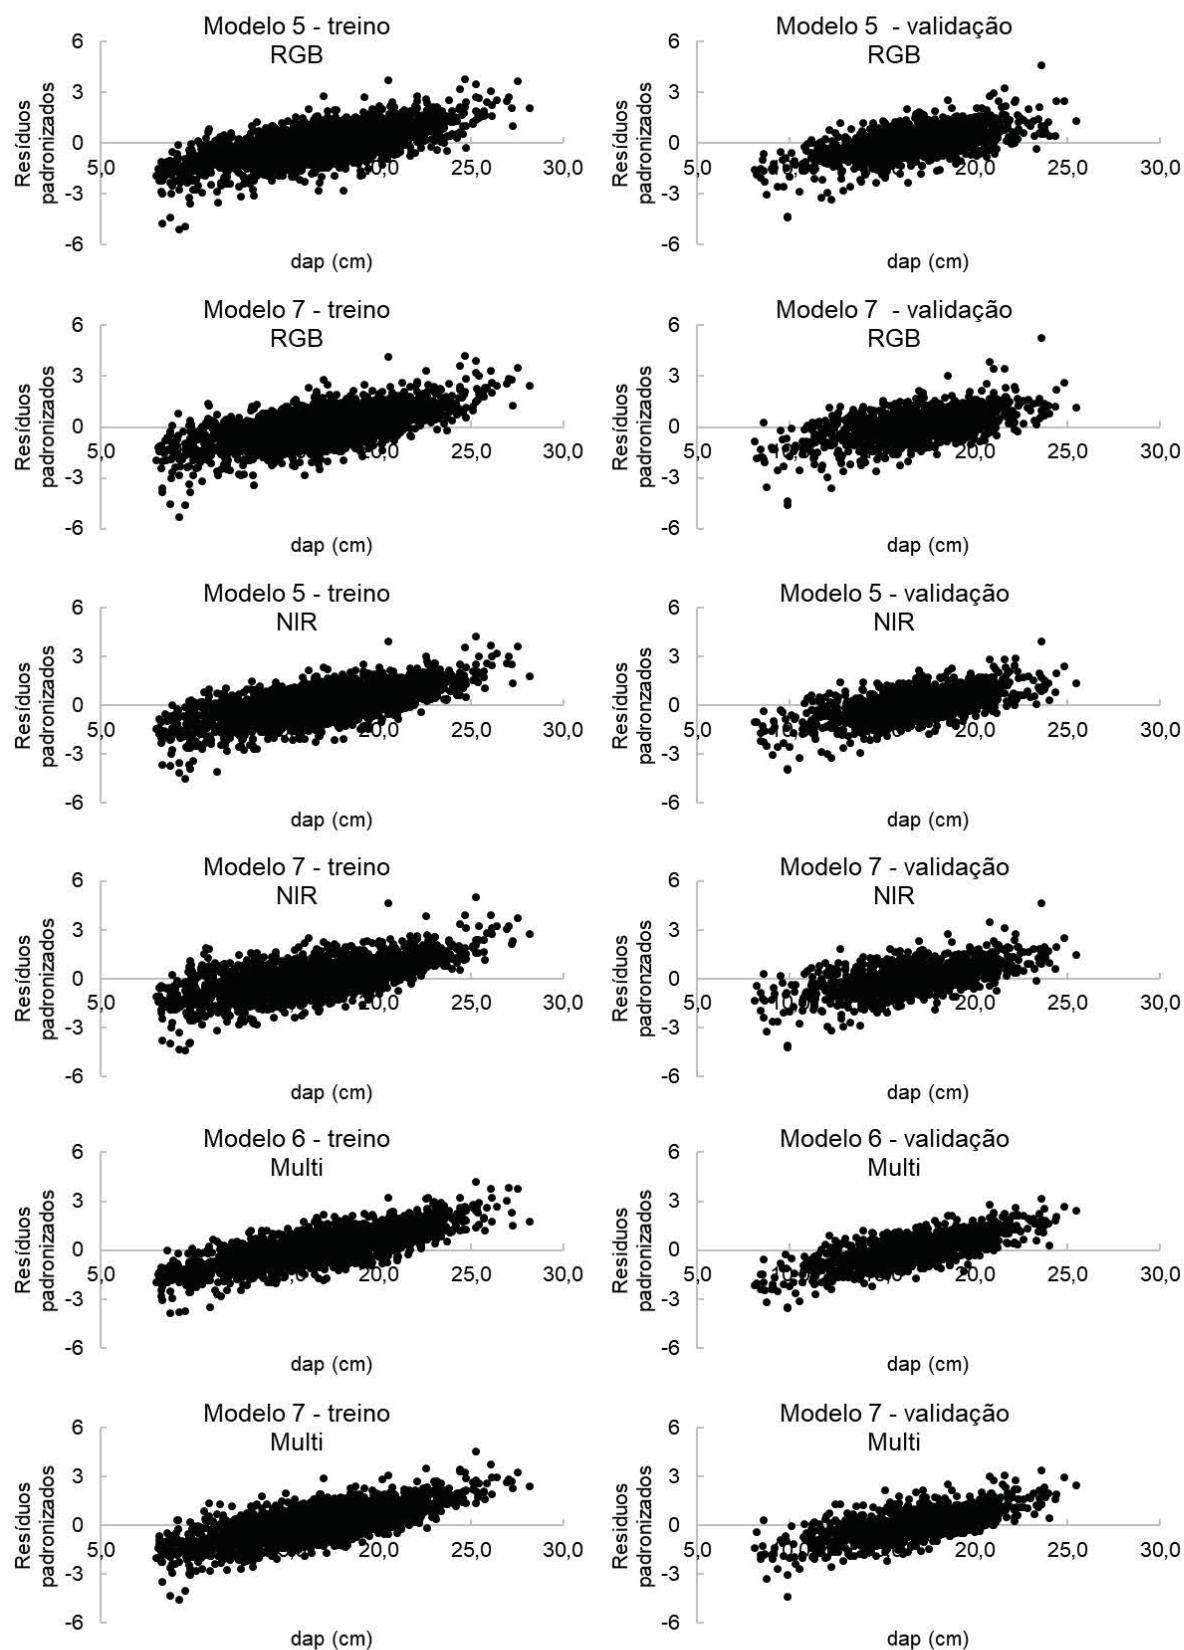
TABELA 62 - MELHORES EQUAÇÕES ESTIMATIVAS DE DAP PARA O TALHÃO *PINUS 2*

Câmera	N	Equações
RGB	5	$dap = -6,80011 + 2,14201*CHM_med + 0,878402*CHM_stdv - 0,890963*CHM_max - 0,143948*Red_med + 0,290327*Red_stdv + 0,175129*Gre_med + 0,00293152*Blue_sum - 0,102934*Blue_stdv - 0,260869*Intens_stdv$
	7	$dap = -15,38 + 3,22009*CHM_med + 2,26275*CHM_stdv - 0,000274722*MDS_sum + 0,0104014*Blue_sum - 0,0603411*CHM_var_max - 0,684176*CHM_dis_max + 0,604625*Red_dis_med - 0,00181512*Blue_var_sum - 0,0218777*Blue_var_stdv - 0,033339*Blue_dis_sum$
NIR	5	$dap = -5,4766 + 0,0384305*CHM_sum + 2,05816*CHM_med + 3,96357*CHM_stdv - 1,45868*CHM_max - 1,45981*MDS_stdv + 0,00586611*Red_med - 0,000188629*Red_stdv - 0,00545558*Intens_med$
	7	$dap = -21,243 + 5,47652*CHM_med + 2,31249*CHM_stdv - 0,418525*CHM_max - 1,23345*MDS_stdv + 0,00370326*Red_med - 0,00279897*Red_stdv + 0,0000240463*Gre_sum - 0,00316959*Intens_med + 0,0026943*Intens_stdv + 0,191653*CHM_var_stdv - 0,12352*CHM_var_max + 5,19536*Red_hom_stdv - 0,149076*Red_ent_sum - 0,0375587*Gre_var_med$
Multi	6	$dap = 11,0798 - 0,00208125*CHM_var_sum + 0,277743*CHM_var_med + 0,284504*CHM_var_stdv - 0,193079*CHM_var_max - 7,21038*CHM_hom_med - 11,7258*CHM_hom_stdv + 6,94291*CHM_hom_max + 0,0298755*MDS_var_med - 0,03012*MDS_var_max + 0,0379694*MDS_ent_sum + 2,65134*MDS_2m_max + 0,0243643*Red_var_med - 0,0576276*Red_var_stdv + 0,00075075*Gre_var_sum + 0,0389236*NIR_var_stdv + 4,70304*NIR_2m_sum - 89,6361*NIR_2m_med - 18,1796*NIR_2m_stdv - 5,71427*RE_hom_med - 2,86212*RE_dis_med$
	7	$dap = 6,68982*CHM_med + 3,11005*MDS_med + 4,83588*MDS_stdv - 3,14235*MDS_max + 43,6088*Gre_sum + 85,4507*NDVI_stdv + 10,2334*NDRE_med - 31,9257*NDRE_stdv - 0,0690173*CHM_var_med + 0,189356*CHM_var_stdv - 0,129106*CHM_var_max - 0,0661534*Red_con_sum + 1,27817*Red_con_med - 0,00539902*Gre_var_sum - 0,241973*Gre_hom_sum + 0,0246845*Gre_con_sum - 3,28759*Gre_dis_med + 0,0300737*NIR_var_stdv - 0,0386633*NIR_dis_sum - 0,167322*RE_con_med$

FONTE: A autora (2018).

Os resíduos das equações apresentados na TABELA 62 podem ser visualizados na FIGURA 42. Novamente observa-se o padrão de superestimativa dos valores de dap das árvores menores, e subestimativa das árvores maiores.

FIGURA 42 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE DAP NO TALHÃO *PINUS 2*, PARA DADOS DE TREINO E VALIDAÇÃO



FONTE: A autora (2018).

As equações estimativas de altura do talhão *Pinus 2*, com a três câmeras, estão apresentadas na TABELA 63. A câmera NIR, seguida pela RGB, novamente apresentou os melhores resultados. Se comparados com as equações estimativas de dap, observa-se que os valores de R^2_{aj} são ligeiramente inferiores, porém os resultados em relação ao erro ($S_{xy}\%$) são melhores. Os valores de erro e R^2_{aj} são similares aos observados no talhão *Eucalyptus*, e superiores em relação ao talhão *Pinus 1*.

A melhor equação, para as três câmeras, foi o que teve todas as variáveis como entrada (equação 7), enquanto que a segunda melhor equação variou entre o 5 (variáveis estruturais e espectrais) para as câmeras NIR e Multi, e o 6 (textura das variáveis estruturais e espectrais), para a câmera RGB. A equação 7 apresentou os melhores resultados, com 0,52 e 0,47 de R^2_{aj} e 8,28% e 8,02% de erro, para dados de treino e validação, respectivamente, com a câmera NIR.

TABELA 63 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO *PINUS 2*

Câmera	N	Variáveis	Treino				Validação		
			R ² aj.	Syx %	Nota	F calc.	F tab. 1%.	R ² aj.	Syx %
RGB	1	Estrutural	0,41	9,21	8	280,36**	2,65	0,41	8,51
	2	Espectral	0,27	10,28	12	146,42**	2,65	0,28	9,39
	3	Textura espectral	0,26	10,29	14	78,45**	2,14	0,26	9,51
	4	Textura estrutural	0,41	9,22	10	177,86**	2,25	0,37	8,75
	5	Estrutural + espectral	0,47	8,72	6	251,48**	2,33	0,45	8,17
	6	Text. estrutural + text. espectral	0,48	8,68	4	142,73**	1,94	0,43	8,38
	7	Todas	0,50	8,50	2	214,88**	2,14	0,47	8,05
NIR	1	Estrutural	0,46	8,78	8	405,85**	2,81	0,44	8,26
	2	Espectral	0,20	10,76	12	228,95**	3,79	0,23	9,71
	3	Textura espectral	0,17	10,96	14	62,89**	2,41	0,20	9,89
	4	Textura estrutural	0,45	8,92	10	454,44**	3,02	0,41	8,46
	5	Estrutural + espectral	0,50	8,50	4	348,60**	2,52	0,46	8,11
	6	Text. estrutural + text. espectral	0,47	8,71	6	230,21**	2,25	0,44	8,28
	7	Todas	0,52	8,28	2	281,77**	2,25	0,47	8,02
Multi	1	Estrutural	0,32	9,89	8	222,45**	2,81	0,29	9,31
	2	Espectral	0,14	11,11	14	52,71**	2,41	0,14	10,24
	3	Textura espectral	0,14	11,11	12	52,92**	2,41	0,13	10,33
	4	Textura estrutural	0,31	9,99	10	114,09**	2,25	0,27	9,48
	5	Estrutural + espectral	0,35	9,71	4	114,85**	2,14	0,30	9,28
	6	Text. estrutural + text. espectral	0,33	9,80	6	100,90**	2,09	0,30	9,28
	7	Todas	0,40	9,30	2	99,05**	1,91	0,35	8,95

Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi <0,0001, enquanto que o p-valor de todas as variáveis <0,05.

FONTE: A autora (2018).

As duas melhores equações estimativas de altura do talhão *Pinus 2*, com cada câmera, estão apresentados na TABELA 64. Destaca-se que as equações com a

câmera NIR apresentam menor número de variáveis selecionadas, apesar de apresentarem os melhores resultados de estimativa.

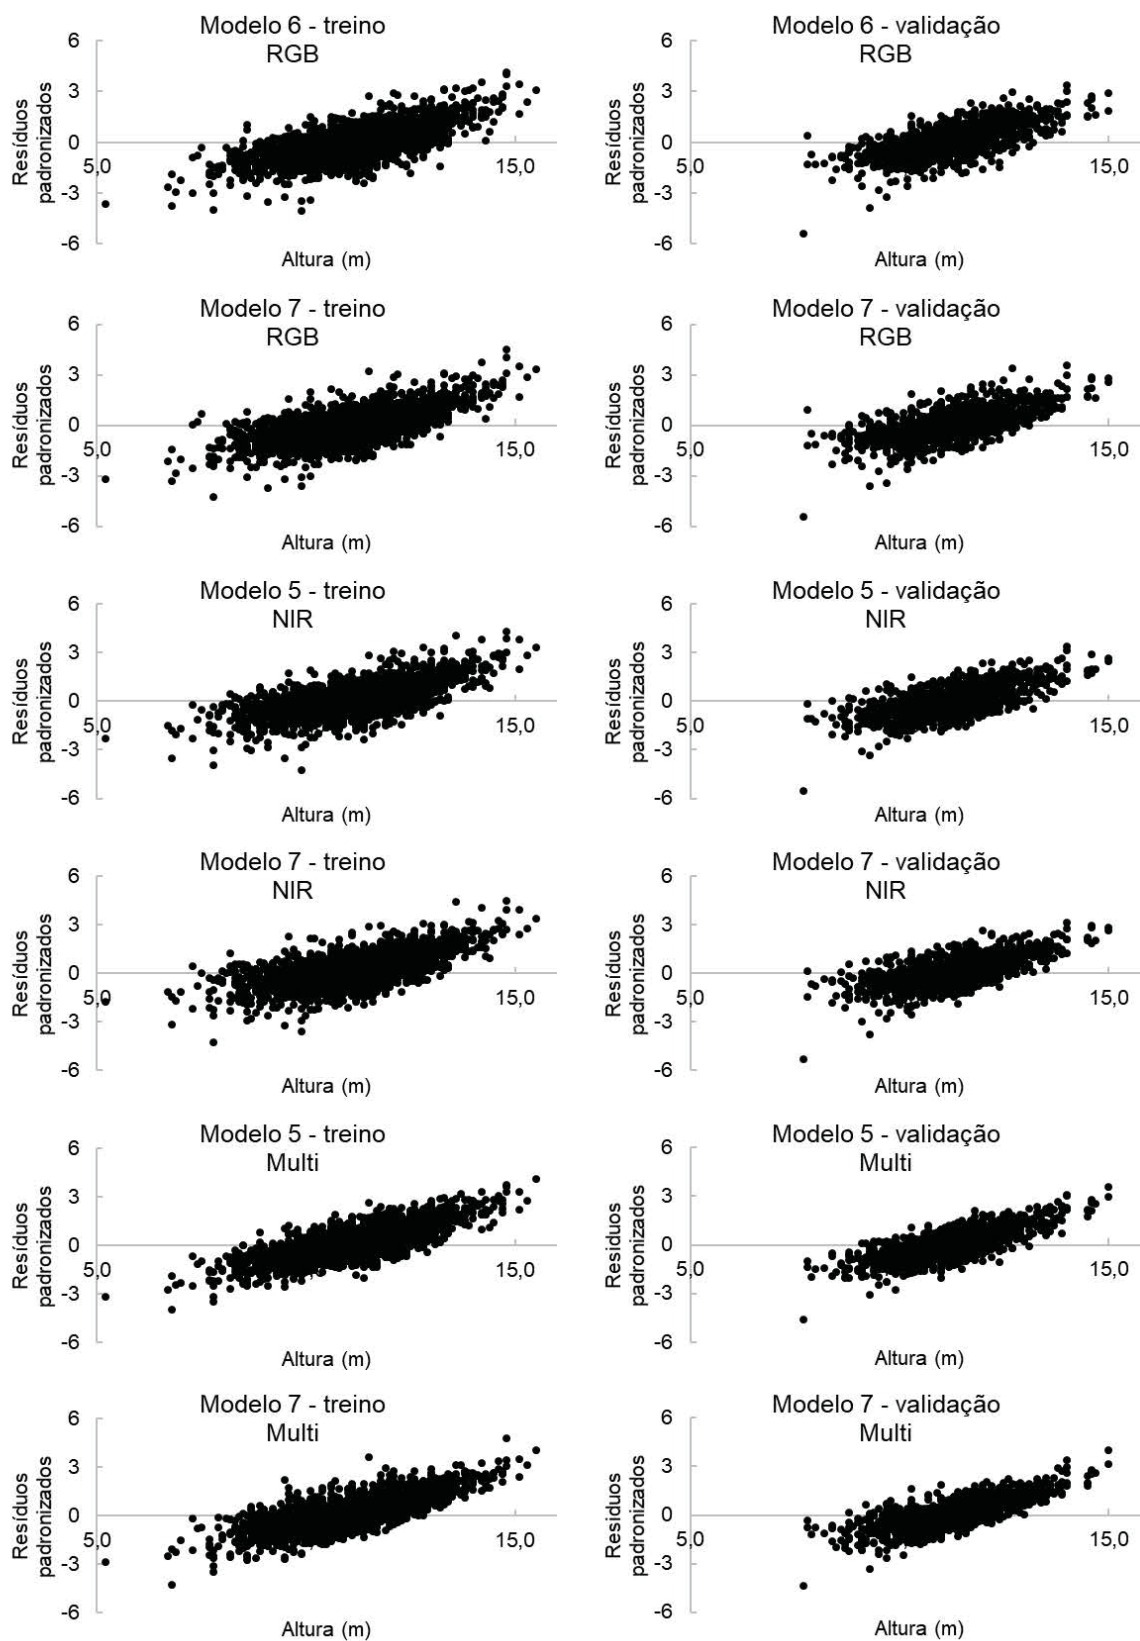
TABELA 64 - MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA PARA O TALHÃO *PINUS 2*

Câmera	N	Equações
RGB	6	Altura = $6,16965 + 0,0463058*CHM_var_med + 0,0268617*CHM_var_stdv - 0,0222414*CHM_var_max + 0,0223002*CHM_ent_sum + 0,0161975*MDS_var_med + 0,023935*MDS_var_stdv - 0,0168701*MDS_var_max + 1,80429*MDS_hom_max - 0,288522*MDS_dis_max + 0,0237432*MDS_ent_sum - 0,318051*MDS_ent_max - 14,2633*Red_2m_med - 0,0234674*Gre_con_stdv + 0,013424*Gre_dis_sum - 0,000621601*Blue_var_sum + 0,0208397*Blue_var_mean + 0,0270298*Blue_con_stdv - 0,429644*Blue_dis_med$
	7	Altura = $1,43646*CHM_med + 1,01347*CHM_stdv + 0,0180796*Red_stdv + 0,0312948*Blue_med - 0,0217693*CHM_var_max + 0,217533*CHM_2m_sum - 5,85786*CHM_2m_med - 0,000707948*MDS_var_max - 0,225725*MDS_dis_max - 0,00372172*Red_var_stdv - 12,9018*Red_2m_med - 0,15038*Gre_dis_stdv - 0,000145008*Blue_var_sum - 0,0973321*Blue_dis_med$
NIR	5	Altura = $8,798 - 0,00469138*CHM_sum + 0,991528*CHM_med + 1,21606*CHM_stdv + 0,690571*MDS_med - 0,698891*MDS_max + 0,0000378646*Red_sum + 0,0000335928*NIR_stdv - 0,0000347368*Intens_sum$
	7	Altura = $-3,17321 + 1,8589*CHM_med + 1,92133*CHM_stdv + 0,00000976438*Red_sum - 0,0310581*CHM_var_max - 0,0161006*MDS_con_sum - 0,000368912*Red_var_sum - 0,00129014*Red_con_sum - 0,0311879*Red_ent_sum - 0,306048*Gre_2m_sum + 0,92111*NIR_hom_med + 0,0268236*NIR_con_med$
Multi	5	Altura = $19,6767 - 4,19939*Area - 0,0288903*CHM_sum + 1,36484*CHM_med + 1,54164*MDS_med + 1,47402*MDS_stdv - 1,56801*MDS_max + 353,417*Red_med + 132,716*Gre_stdv - 22,2697*NIR_med - 20,9541*RE_stdv + 1,63368*NDVI_sum + 20,9214*NDVI_stdv - 18,9835*NDRE_stdv$
	7	Altura = $13,7314 + 2,46871*CHM_med + 1,03434*CHM_stdv + 0,807101*MDS_med + 1,12979*MDS_stdv - 0,83418*MDS_max + 362,363*Red_stdv + 1,07345*RE_sum + 33,2714*RE_med + 21,4217*NDVI_stdv - 12,4395*NDRE_stdv - 0,000757697*CHM_var_sum - 0,0243339*CHM_var_med - 0,0208324*CHM_var_max - 0,222883*CHM_dis_max + 1,15904*MDS_2m_max - 0,0402991*Red_var_stdv - 0,0482599*RE_var_med + 0,0142909*RE_var_stdv - 0,0750408*RE_con_med$

FONTE: A autora (2018).

Os gráficos de resíduos para as melhores equações estimativas de altura estão apresentados na FIGURA 43, para os dados de treino e validação. Novamente é observada a mesma tendência de todas as equações anteriores, de superestimar a altura nas árvores mais baixas e subestimar nas mais altas.

FIGURA 43 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE ALTURA NO TALHÃO *PINUS 2*, PARA DADOS DE TREINO E VALIDAÇÃO



FONTE: A autora (2018).

O resumo estatístico das equações estimativas de volume para o talhão *Pinus 2* está apresentado na TABELA 65. Assim como para dap e altura, a câmera NIR apresentou os melhores resultados, seguida pela câmera RGB. A equação que teve todas as variáveis como entrada (equação 7) apresentou os melhores resultados para as três câmeras, apresentando $R^2_{aj.}$ de 0,58 e 0,53 e erro de 29,07% e 28,23% para dados de treino e validação, com a câmera NIR. A segunda melhor equação novamente variou entre a equação 5, para as câmeras RGB e NIR, e 6 para a câmera Multi.

Da mesma forma como observado no talhão *Eucalyptus*, as equações de volume apresentaram os melhores valores em termos de $R^2_{aj.}$, quando comparados com as equações estimativas de dap e altura. Porém, os valores de erro das equações de volume são superiores, neste caso geralmente superiores a 30%.

TABELA 65 - RESUMO ESTATÍSTICO DAS EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO *PINUS 2*

Câmera	N	Variáveis	Treino				Validação	
			$R^2_{aj.}$	Syx %	Nota	F calc.	F tab. 1%.	$R^2_{aj.}$ Syx %
RGB	1	Estrutural	0,37	35,53	14	418,07**	3,33	0,39 32,03
	2	Espectral	0,44	33,66	8	436,72**	3,02	0,43 30,95
	3	Textura espectral	0,42	34,27	10	201,24**	2,33	0,43 31,08
	4	Textura estrutural	0,40	34,71	12	135,33**	2,09	0,39 32,09
	5	Estrutural + espectral	0,55	29,98	4	387,21**	2,41	0,54 27,95
	6	Text. estrutural + text. espectral	0,54	30,37	6	222,06**	2,04	0,53 28,21
	7	Todas	0,57	29,36	2	235,14**	2,01	0,56 27,40
NIR	1	Estrutural	0,45	33,20	10	332,23**	2,65	0,47 30,06
	2	Espectral	0,37	35,64	12	411,17**	3,33	0,37 32,63
	3	Textura espectral	0,32	36,86	14	151,02**	2,41	0,33 33,68
	4	Textura estrutural	0,47	32,77	8	223,94**	2,25	0,45 30,51
	5	Estrutural + espectral	0,55	30,10	4	381,71**	2,41	0,53 28,21
	6	Text. estrutural + text. espectral	0,54	30,39	6	195,60**	1,97	0,49 29,31
	7	Todas	0,58	29,07	2	216,47**	1,94	0,53 28,23
Multi	1	Estrutural	0,34	36,46	8	241,28**	2,81	0,36 32,94
	2	Espectral	0,21	39,92	14	148,47**	3,02	0,20 36,84
	3	Textura espectral	0,25	38,92	12	93,30**	2,33	0,20 36,73
	4	Textura estrutural	0,33	36,71	10	126,99**	2,25	0,32 33,90
	5	Estrutural + espectral	0,37	35,48	6	168,92**	2,33	0,37 32,52
	6	Text. estrutural + text. espectral	0,39	35,08	4	119,82**	2,04	0,36 32,91
	7	Todas	0,46	33,01	2	82,95**	1,72	0,42 31,35

Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi $<0,0001$, enquanto que o p-valor de todas as variáveis $<0,05$.

FONTE: A autora (2018).

As duas melhores equações, para cada uma das câmeras, estão apresentadas na TABELA 66. As equações para a câmera Multi apresentam um número de variáveis bastante superior aos demais, apesar de os resultados de ajuste serem inferiores.

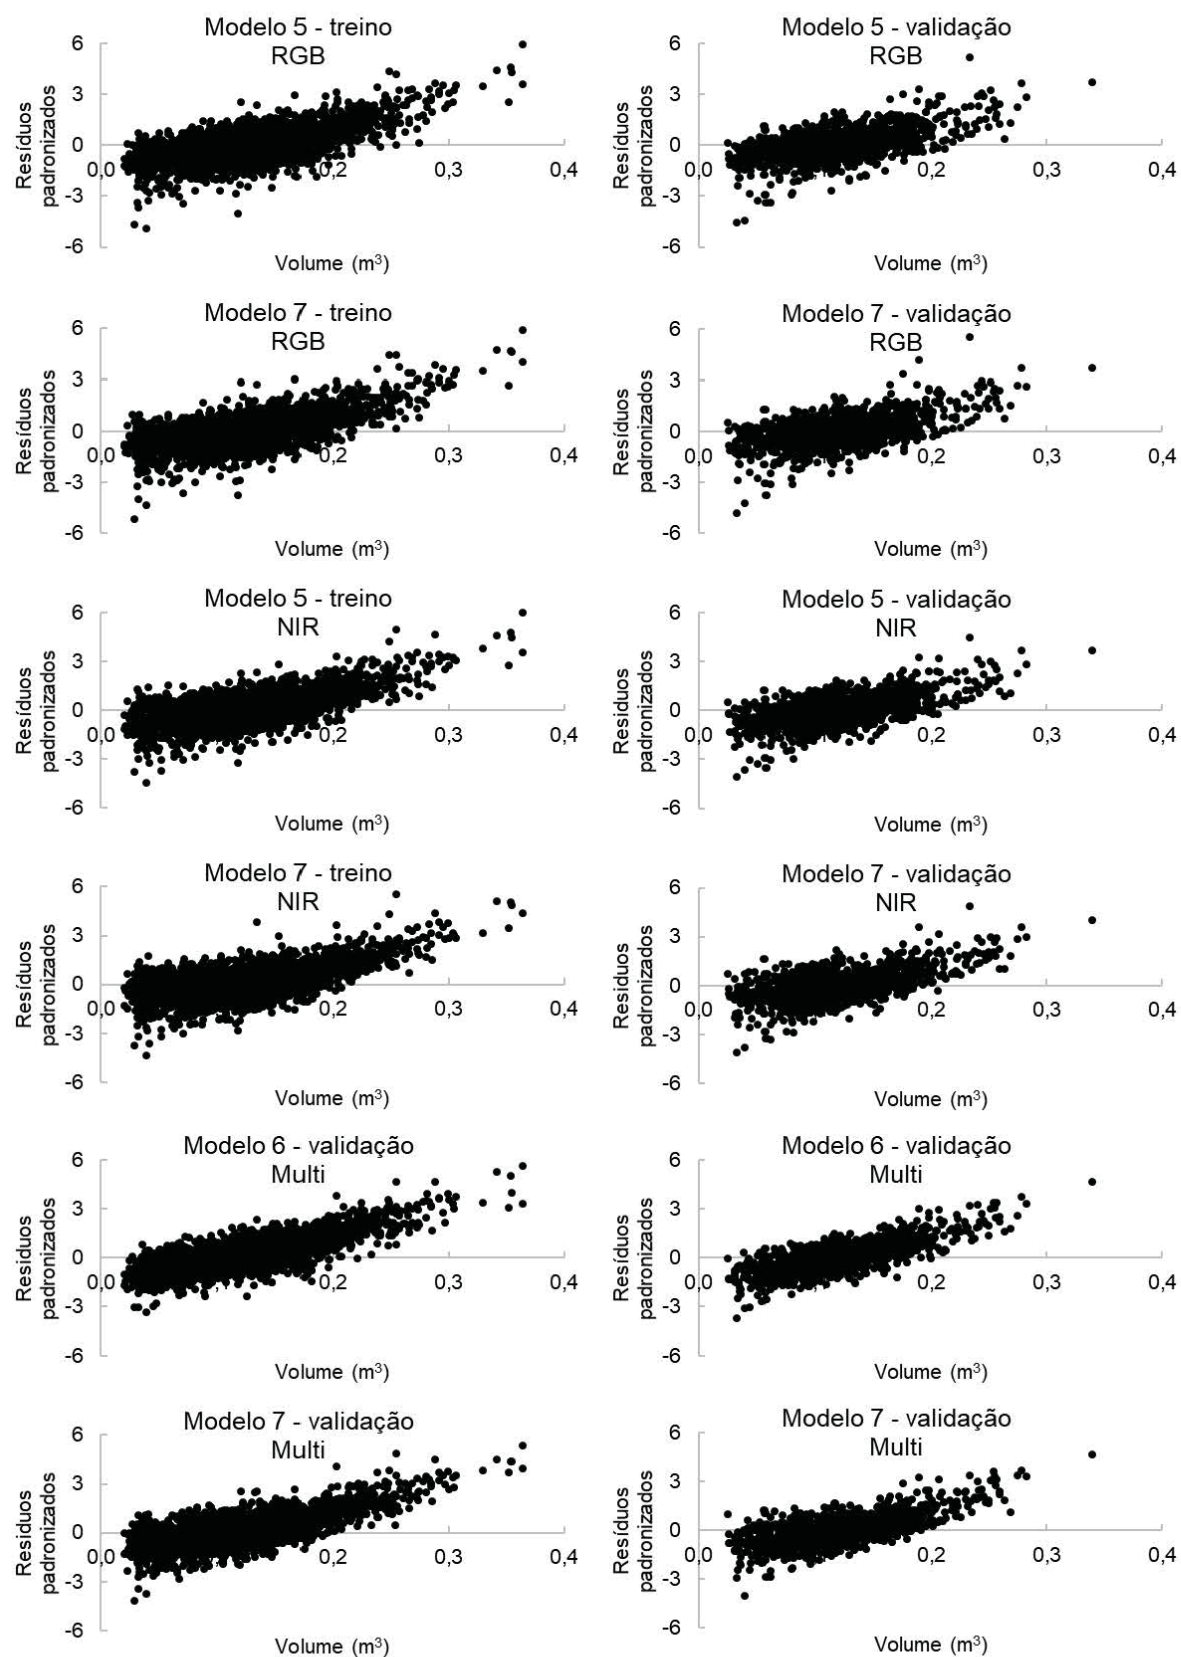
TABELA 66 - MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME PARA O TALHÃO *PINUS 2*

Câmera	N	Equações
RGB	5	Vol = 0,00141673*CHM_sum + 0,0193364*CHM_stdv - 0,0100602*CHM_max - 0,0000119662*MDS_sum + 0,00385736*Red_stdv + 0,000324997*Gre_sum + 0,00165893*Blue_med - 0,00183012*Blue_stdv - 0,000333692*Intens_sum - 0,00352057*Intens_stdv
	7	Vol = -0,36652 + 0,0426657*CHM_med + 0,0347051*CHM_stdv - 0,0124755*Gre_stdv + 0,0000402278*Blue_sum + 0,0012903*Intens_med + 0,0122875*Intens_stdv - 0,000616305*CHM_var_max - 0,00904481*CHM_dis_max - 0,0000127054*MDS_var_max - 0,000454621*Red_var_med + 0,000618736*Gre_var_stdv + 0,00685848*Gre_dis_med + 0,038245*Gre_ent_stdv + 0,0000124063*Blue_var_sum - 0,00110428*Blue_var_stdv - 0,000432597*Blue_dis_sum
NIR	5	Vol = -0,0426003*Area + 0,00108247*CHM_sum + 0,0153391*CHM_med + 0,0398814*CHM_stdv - 0,0117336*CHM_max + 0,00000343793*Red_sum - 0,000053985*Red_stdv - 1,53053E-7*NIR_sum - 0,00000298211*Intens_sum + 0,0000514461*Intens_stdv
	7	Vol = -0,273621 + 0,070688*CHM_med + 0,0226099*CHM_stdv - 0,0216534*MDS_stdv + 0,0000648594*Red_med - 0,0000443491*Red_stdv - 0,0000197746*NIR_med - 0,0000267942*Intens_med + 0,0000386898*Intens_stdv + 0,00264579*CHM_var_stdv - 0,00145584*CHM_var_max - 0,00413496*CHM_con_stdv - 0,000723901*MDS_2m_sum - 0,0000234179*Red_var_sum + 0,0830983*Red_hom_stdv - 0,0541479*Red_ent_md - 0,00070056*Gre_var_med + 0,0000297804*NIR_var_sum + 0,000183108*NIR_var_stdv
Multi	6	Vol = 0,00333392*CHM_var_med + 0,00379483*CHM_var_stdv - 0,00264347*CHM_var_max + 0,00428144*CHM_ent_sum - 0,0861087*CHM_ent_med + 0,000596953*MDS_var_med + 0,000488874*MDS_var_stdv - 0,000612629*MDS_var_max + 0,0145131*MDS_ent_stdv + 0,000301535*Red_var_med - 0,000121087*Red_con_sum + 0,0000144485*Gre_var_sum + 0,000479203*NIR_var_stdv - 0,000204686*RE_var_med - 0,000223921*RE_con_sum + 0,00242494*RE_con_stdv
	7	Vol = 0,00377581*CHM_sum - 0,0000197228*MDS_sum + 0,0493966*MDS_med + 0,0716185*MDS_stdv - 0,0496845*MDS_max - 6,52905*Red_stdv + 0,406015*Gre_sum + 9,63772*Gre_stdv - 0,0623195*NIR_sum + 1,27286*NIR_stdv + 0,116484*RE_sum - 2,87021*RE_stdv + 1,47952*NDVI_stdv + 0,665006*NDRE_med - 0,404394*NDRE_stdv - 0,000132485*CHM_var_sum + 0,00247908*CHM_var_med + 0,0023663*CHM_var_stdv - 0,00173912*CHM_var_max - 0,00114437*CHM_2m_sum - 0,0246653*MDS_con_med + 0,000743739*MDS_ent_sum + 0,0294862*MDS_2m_max - 0,00300313*Red_dis_sum + 0,0591335*Red_dis_med - 0,0000358471*Gre_var_sum - 0,00112668*Gre_var_stdv - 0,0005021*NIR_dis_sum - 0,0000513278*RE_var_sum + 0,00212452*RE_var_stdv

FONTE: A autora (2018).

Os gráficos de dispersão de resíduos das equações selecionadas estão apresentados na FIGURA 44. Novamente é possível perceber a tendência de superestimar nas menores árvores e subestimar nas maiores.

FIGURA 44 - ANÁLISE DE RESÍDUO DAS MELHORES EQUAÇÕES ESTIMATIVAS DE VOLUME NO TALHÃO *PINUS 2*, PARA DADOS DE TREINO E VALIDAÇÃO



FONTE: A autora (2018).

4.4.4 Inclusão de fator de correção nas equações estimativas

Dada a presença de tendência de superestimativa dos menores valores de dap, altura e volume, e da subestimativa dos maiores valores dessas mesmas variáveis, foi realizada a inclusão de um fator de correção nas equações, com o objetivo de corrigir as tendências. Para avaliar o efeito desse fator, somente a equação estimativa com melhor ajuste, para cada variável, foi selecionada. Em todos os casos, a equação 7, que combinou todas os tipos de variáveis, obteve os melhores resultados, e, portanto, foi utilizada nessa etapa.

Os fatores de correção (FC) utilizados estão apresentados TABELA 67, e os resultados do ajuste, com e sem o fator de correção, estão apresentados na TABELA 68. É importante lembrar que as classes de intervalos foram calculadas com base em variações da média em função de valores de desvio padrão, portanto não são intervalos equidistantes.

TABELA 67 – LIMITES DE CLASSES E FATORES DE CORREÇÃO PARA DAP, ALTURA E VOLUME OBSERVADOS NO TALHÃO *EUCALYPTUS*

Classe	dap (cm)		Altura (m)		Volume (m ³)	
	Intervalo	FC	Intervalo	FC	Intervalo	FC
1	<13,95	0,89	<17,73	0,85	<0,1201	0,51
2	13,95 I- 16,50	0,90	17,73 I- 19,48	0,96	0,1201 I- 0,1983	0,86
3	16,50 I- 19,15	0,96	19,48 I- 21,30	0,99	0,1983 I- 0,2797	0,89
4	19,15 I- 21,81	1,00	21,30 I- 23,13	1,02	0,2797 I- 0,3612	0,98
5	21,81 I- 24,35	1,10	23,13 I- 24,88	1,05	0,3612 I- 0,4394	1,06
6	≥24,35	1,13	≥24,88	1,15	≥0,4394	1,32

Em que: FC = fator de correção.

FONTE: A autora (2018).

TABELA 68 – COMPARATIVO DA ESTIMATIVA DE DAP, ALTURA E VOLUME COM E SEM A INCLUSÃO DE FATOR DE CORREÇÃO NO TALHÃO *EUCALYPTUS*

Variável	Equação	Treino				Validação	
		R ² aj.	Syx %	F calc.	F tab. 1%.	R ² aj.	Syx %
dap	7 NIR + FC	0,70	7,57	206,30**	1,98	0,71	6,86
Altura	7 Multi + FC	0,72	4,56	144,71**	1,77	0,74	3,98
Volume	7 NIR + FC	0,76	14,39	230,72**	1,89	0,74	13,81
dap	7 NIR	0,58	8,98	128,95**	2,01	0,56	8,44
Altura	7 Multi	0,52	5,94	64,91**	1,79	0,45	5,78
Volume	7 NIR	0,59	18,57	115,04**	1,92	0,60	16,97

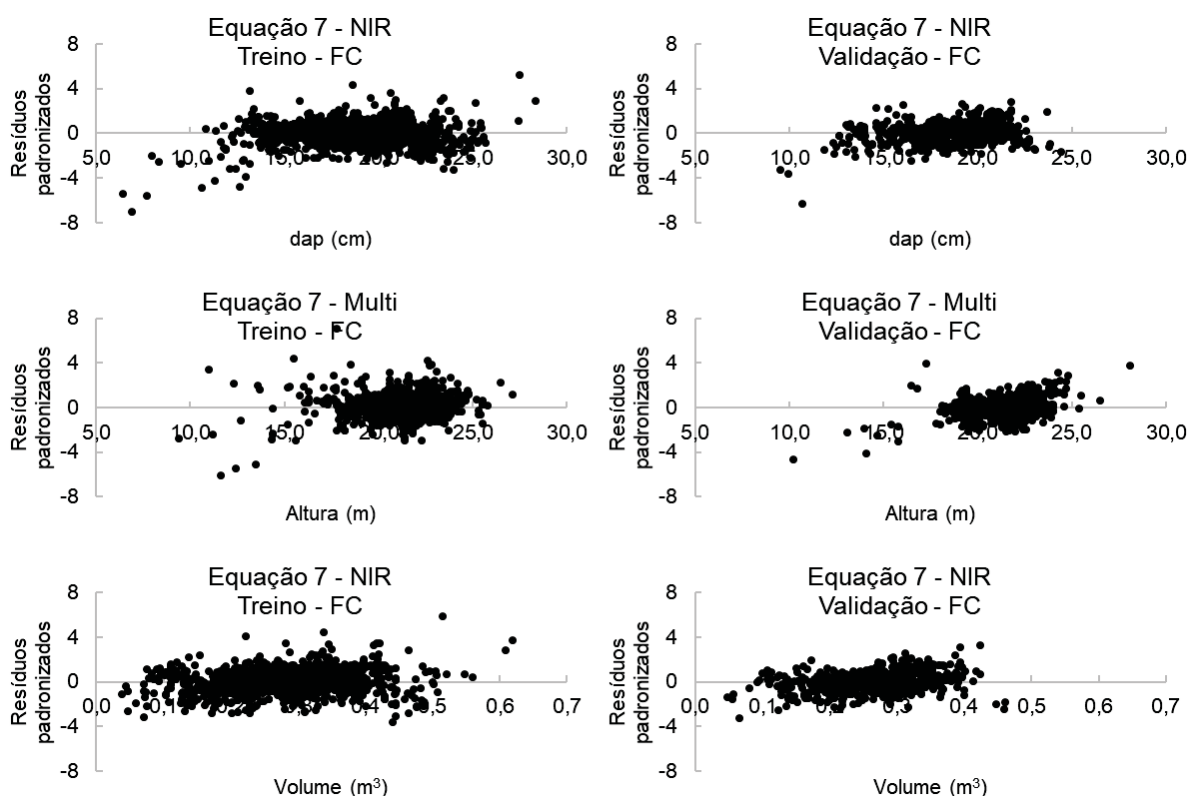
Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi <0,0001, enquanto que o p-valor de todas as variáveis <0,05; FC = fator de correção.

FONTE: A autora (2018).

Em todos os casos, a inclusão do fator de correção acarretou na melhoria dos ajustes, tanto pelos valores de R²aj. como Syx % dos dados de treino e validação. As equações que antes apresentavam R²aj. de pouco mais que 0,5, apresentam agora

valores acima de 0,7, para ambos dados de treino e validação. Nas equações de dap e altura, o erro foi reduzido em torno de 1,5%, e em cerca de 3% para volume, tanto para treino como validação. Pelos gráficos de resíduos, conforme a FIGURA 45, é possível observar que a tendência de superestimativa de árvores menores e subestimativa das maiores não ocorre.

FIGURA 45 - ANÁLISE DE RESÍDUO AS EQUAÇÕES ESTIMATIVAS PARA DAP, ALTURA E VOLUME COM A INCLUSÃO DO FATOR DE CORREÇÃO PARA O TALHÃO *EUCALYPTUS*



FONTE: A autora (2018).

As classes e os fatores de correção utilizados no talhão *Pinus* 1 estão na TABELA 69. A primeira classe de volume não apresenta fator de correção porque somente três árvores foram encontradas nessa classe, portanto os volumes foram corrigidos com os valores da classe 2.

Os ajustes para o talhão *Pinus* 1 estão apresentados na TABELA 70. Observa-se que nesse caso também houve melhoria nos ajustes das equações, tanto para $R^2_{aj.}$ como $Syx\%$, e nesse caso, a melhoria dos ajustes foi mais substancial em comparação ao talhão *Eucalyptus*. Os valores de $R^2_{aj.}$, que variavam entre 0,27 e 0,37 nas equações originais, variam de 0,71 a 0,75 com o uso do fator de correção, considerando os dados de treino. Os erros também apresentaram melhoria

substancial, variando entre 13,87% e 36,99% nas equações originais, e 9,62% e 25,11% nas equações com o fator de correção, considerando os dados de treino. Os mesmos padrões são observados nos dados de validação.

TABELA 69 – LIMITES DE CLASSES E FATORES DE CORREÇÃO PARA DAP, ALTURA E VOLUME OBSERVADOS NO TALHÃO *PINUS 1*

Classe	dap (cm)		Altura (m)		Volume (m ³)	
	Intervalo	FC	Intervalo	FC	Intervalo	FC
1	<14,88	0,54	<10,87	0,64	<0,0314	-
2	14,88 I- 19,28	0,80	10,87 I- 13,56	0,81	0,0314 I- 0,1911	0,52
3	19,28 I- 23,86	0,95	13,56 I- 16,36	1,00	0,1911 I- 0,3575	0,84
4	23,86 I- 28,44	1,06	16,36 I- 19,16	1,07	0,3575 I- 0,5239	1,17
5	28,44 I- 32,84	1,19	19,16 I- 21,85	1,10	0,5239 I- 0,6836	1,35
6	≥32,84	1,32	≥21,85	1,27	≥0,6836	1,67

Em que: FC = fator de correção.

FONTE: A autora (2018).

TABELA 70 – COMPARATIVO DA ESTIMATIVA DE DAP, ALTURA E VOLUME COM E SEM A INCLUSÃO DE FATOR DE CORREÇÃO NO TALHÃO *PINUS 1*

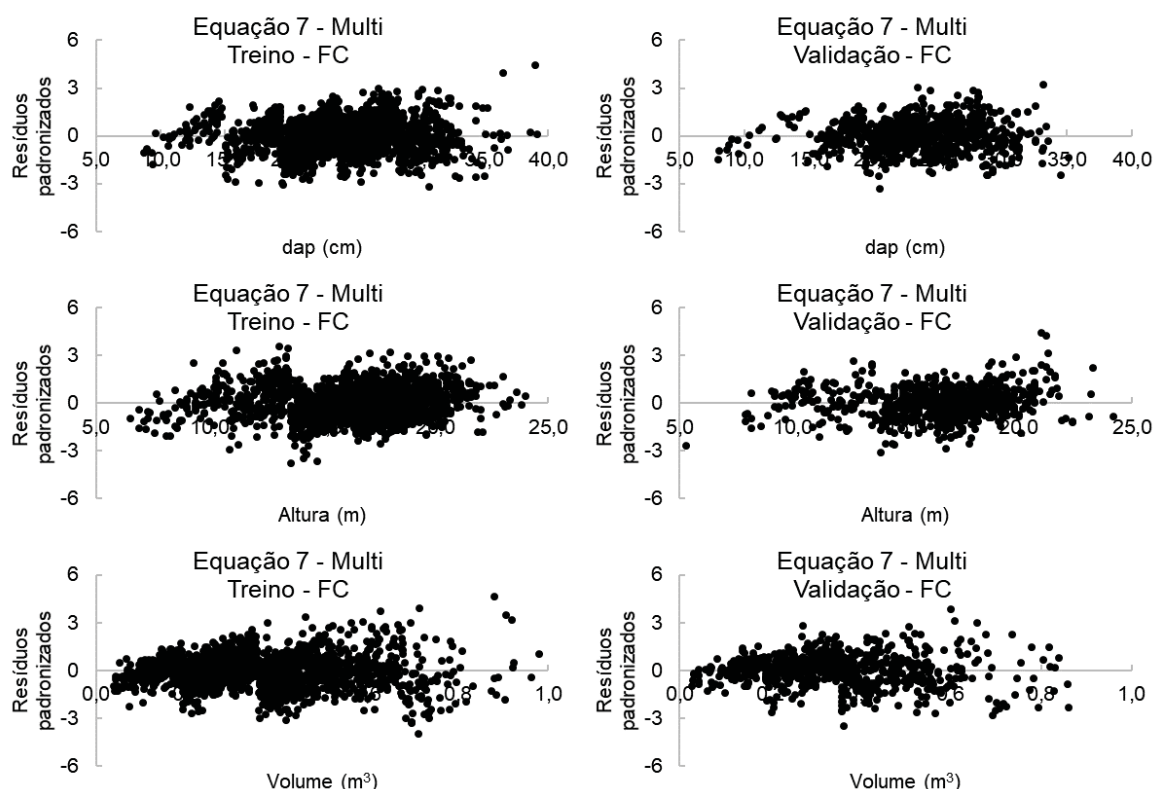
Variável	Equação	Treino				Validação	
		R ² aj.	Syx %	F calc.	F tab. 1%.	R ² aj.	Syx %
dap	7 Multi + FC	0,75	9,62	515,45**	2,26	0,77	9,53
Altura	7 Multi + FC	0,73	8,85	400,97**	2,14	0,74	9,13
Volume	7 Multi + FC	0,71	25,11	289,85**	2,01	0,70	25,67
dap	7 Multi	0,27	16,41	71,09**	2,33	0,29	16,60
Altura	7 Multi	0,34	13,87	83,89**	2,19	0,30	14,93
Volume	7 Multi	0,37	36,99	74,81**	2,05	0,38	36,69

Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi <0,0001, enquanto que o p-valor de todas as variáveis <0,05; FC = fator de correção.

FONTE: A autora (2018).

Os gráficos de resíduos para as equações com a inclusão do fator de correção, para o talhão *Pinus 1*, estão apresentados na FIGURA 46. Observa-se que a tendência de superestimativa de árvores menores e subestimativa das maiores não ocorre.

FIGURA 46 - ANÁLISE DE RESÍDUO DAS EQUAÇÕES ESTIMATIVAS PARA DAP, ALTURA E VOLUME COM A INCLUSÃO DO FATOR DE CORREÇÃO, PARA O TALHÃO *PINUS 1*



FONTE: A autora (2018).

Na TABELA 71 estão os limites e os fatores utilizados para a correção dos valores estimados para o talhão *Pinus 2*. Já na TABELA 72 estão apresentados os resultados comparativos das equações estimativas com e sem a inclusão do fator de correção, para as variáveis dap, altura e volume. Da mesma forma que para os outros dois talhões, houve melhoria nos ajustes, tanto para $R^2_{aj.}$ como Syx%. Os valores de $R^2_{aj.}$ originalmente em torno de 0,5 e 0,4, encontram-se acima de 0,7 e 0,6 com a inclusão do fator de correção, considerando os dados de treino e validação, respectivamente.

TABELA 71 – LIMITES DE CLASSES E FATORES DE CORREÇÃO PARA DAP, ALTURA E VOLUME OBSERVADOS NO TALHÃO *PINUS 2*

Classe	dap (cm)		Altura (m)		Volume (m³)	
	Intervalo	FC	Intervalo	FC	Intervalo	FC
1	<9,57	0,67	<8,47	0,87	<0,0145	0,15
2	9,57 13,03	0,84	8,47 9,75	0,95	0,0145 0,0663	0,75
3	13,03 16,63	0,97	9,75 11,08	0,95	0,0663 0,1203	0,85
4	16,63 20,23	0,98	11,08 12,40	0,98	0,1203 0,1743	1,09
5	20,23 23,69	1,13	12,40 13,68	1,11	0,1743 0,2261	1,12
6	≥23,69	1,25	≥13,68	1,16	≥0,2261	1,44

Em que: FC = fator de correção.

FONTE: A autora (2018).

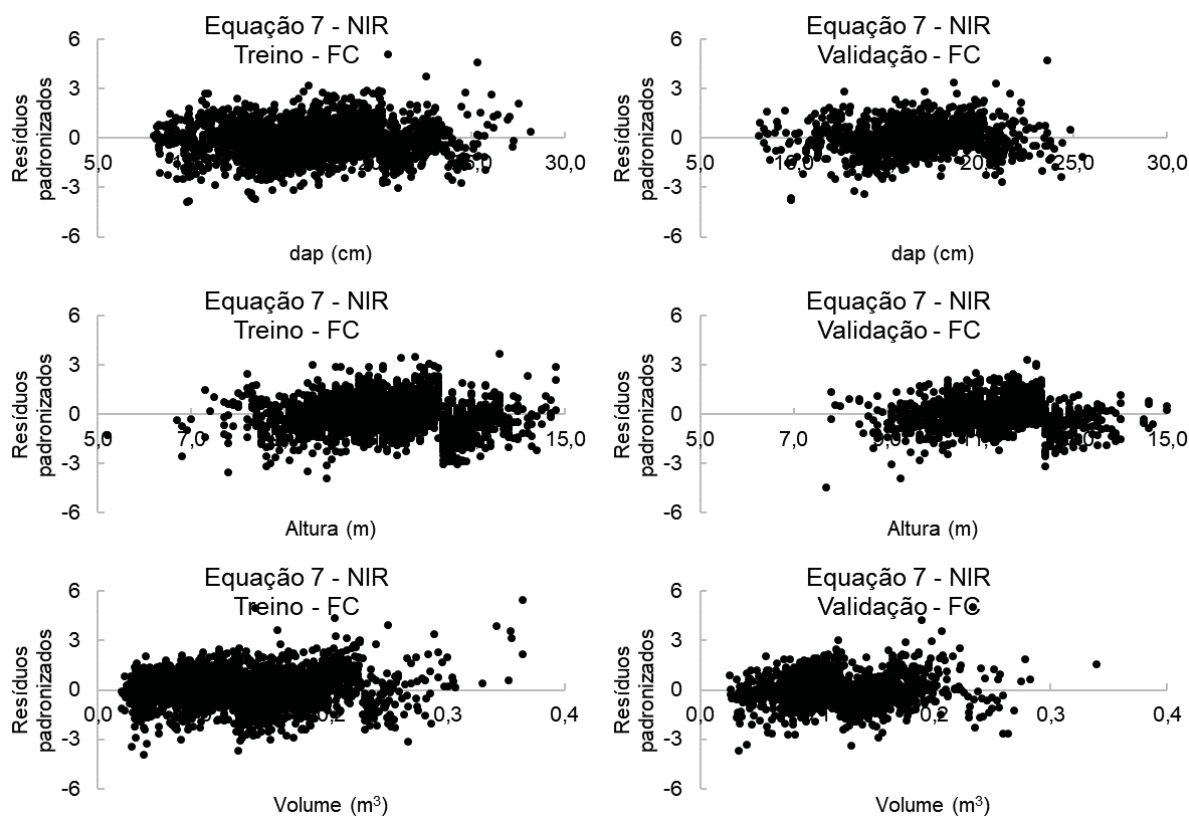
TABELA 72 – COMPARATIVO DA ESTIMATIVA DE DAP, ALTURA E VOLUME COM E SEM A INCLUSÃO DE FATOR DE CORREÇÃO NO TALHÃO *PINUS 2*

Variável	Equação	Treino				Validação	
		R ² aj.	Syx %	F calc.	F tab. 1%.	R ² aj.	Syx %
dap	7 NIR + FC	0,75	10,93	549,39**	2,04	0,66	11,41
Altura	7 NIR + FC	0,69	6,67	523,02**	2,19	0,66	6,49
Volume	7 NIR + FC	0,76	22,07	463,64**	1,91	0,72	21,79
dap	7 NIR	0,55	14,50	247,90**	2,09	0,48	14,20
Altura	7 NIR	0,52	8,28	281,77**	2,25	0,47	8,02
Volume	7 NIR	0,58	29,07	216,47**	1,94	0,53	28,23

Notas: ** Significativo a 99% de confiabilidade; p-valor de todas equações foi <0,0001, enquanto que o p-valor de todas as variáveis <0,05; FC = fator de correção.

FONTE: A autora (2018).

Os gráficos de resíduos das equações com a inclusão do fator de correção estão apresentados na FIGURA 47. Da mesma forma como ocorreu nos outros dois talhões, não se observa mais a tendência de superestimativa de árvores menores e subestimativa das maiores que ocorreu nas equações originais.

FIGURA 47 - ANÁLISE DE RESÍDUO DAS EQUAÇÕES ESTIMATIVAS PARA DAP, ALTURA E VOLUME COM A INCLUSÃO DO FATOR DE CORREÇÃO, PARA O TALHÃO *PINUS 2*

FONTE: A autora (2018).

4.4.5 Estimativa do volume total a partir de árvores detectadas automaticamente

Apesar de a análise estatística das equações permitir avaliar a qualidade das estimativas, o erro total das estimativas em nível de árvore individual também depende da qualidade da detecção de árvores no processo. Para avaliar esse efeito, o volume total de cada talhão foi estimado com base na soma do volume calculado para cada uma das árvores detectadas, sendo que a detecção foi realizada com a ferramenta TreeDetect utilizando a banda NIR da câmera NIR, conforme apresentado no Capítulo 3. As equações utilizadas, portanto, são as mesmas apresentadas nos itens 4.4.1 até 4.4.3.

O volume total estimado com cada uma das equações, dado pela somatória do volume individual de cada árvore detectada, está apresentado nas TABELA 73, 74 e 75, para os talhões *Eucalyptus*, *Pinus 1* e *Pinus 2*, respectivamente.

TABELA 73 - ESTIMATIVA DE VOLUME TOTAL DO TALHÃO *EUCALYPTUS* COM BASE NAS ÁRVORES DETECTADAS EM COMPARAÇÃO COM O VOLUME OBTIDO NO CENSO

Fonte de dados	Número de árvores	Volume				Diferença volume	
		Média (m ³)	Mínimo (m ³)	Máximo (m ³)	Total (m ³)	m ³	%
Censo	2.163	0,2672	0,0069	0,6191	577,9757	-	-
Equação 1	2.053	0,2798	-0,4295	0,4798	574,5009	3,4748	0,60
Equação 2	2.053	0,2793	-0,0368	0,5400	573,4775	4,4982	0,78
Equação 3	2.053	0,2679	-0,0179	0,4437	550,0041	27,9715	4,84
Equação 4	2.053	0,2751	-0,2768	0,4408	564,8600	13,1157	2,27
Equação 5	2.053	0,2817	-0,2937	0,4881	578,2863	-0,3106	-0,05
Equação 6	2.053	0,2746	0,0000	0,5104	563,6636	14,3121	2,48
Equação 7	2.053	0,2667	-0,4654	0,4649	547,5980	30,3777	5,26

FONTE: A autora (2018).

TABELA 74 - ESTIMATIVA DE VOLUME TOTAL DO TALHÃO *PINUS 1* COM BASE NAS ÁRVORES DETECTADAS EM COMPARAÇÃO COM O VOLUME OBTIDO NO CENSO

Fonte de dados	Número de árvores	Volume				Diferença volume	
		Média (m ³)	Mínimo (m ³)	Máximo (m ³)	Total (m ³)	m ³	%
Censo	2.797	0,3428	0,0138	1,0609	958,7654	-	-
Equação 1	3.231	0,3157	-0,0159	0,5634	1.019,8728	-61,1074	-6,37
Equação 2	3.231	0,3139	0,1147	0,5702	1.014,1028	-55,3374	-5,77
Equação 3	3.231	0,3149	0,0880	0,6045	1.017,5731	-58,8076	-6,13
Equação 4	3.231	0,3108	0,0763	0,6282	1.004,1069	-45,3415	-4,73
Equação 5	3.231	0,3175	-0,0203	0,5880	1.025,7829	-67,0174	-6,99
Equação 6	3.231	0,3160	0,0810	0,6340	1.020,8374	-62,0719	-6,47
Equação 7	3.231	0,3163	0,0713	0,6261	1.021,8179	-63,0525	-6,58

FONTE: A autora (2018).

TABELA 75 - ESTIMATIVA DE VOLUME TOTAL DO TALHÃO *PINUS* 2 COM BASE NAS ÁRVORES DETECTADAS EM COMPARAÇÃO COM O VOLUME OBTIDO NO CENSO

Fonte de dados	Número de árvores	Volume			Diferença volume	
		Média (m ³)	Mínimo (m ³)	Máximo (m ³)	Total (m ³)	m ³ %
Censo	4.211	0,1141	0,0016	0,3642	480,4826	- -
Equação 1	3.962	0,1103	-0,1872	0,2323	437,2025	43,2801 9,01
Equação 2	3.962	0,1134	-0,0083	0,2744	449,4680	31,0146 6,45
Equação 3	3.962	0,1144	-0,0632	0,2517	453,3816	27,1010 5,64
Equação 4	3.962	0,1103	-0,1174	0,2427	436,8256	43,6571 9,09
Equação 5	3.962	0,1126	-0,1221	0,2537	446,2306	34,2520 7,13
Equação 6	3.962	0,1125	-0,0905	0,2662	445,6526	34,8300 7,25
Equação 7	3.962	0,1115	-0,1747	0,2564	441,8582	38,6244 8,04

FONTE: A autora (2018).

Observa-se que, apesar de em todos os casos existir diferença do número de árvores contabilizado no censo e detectadas, o volume total estimado para os três talhões atinge resultados próximos ao real. Ainda, no caso do volume calculado pelas árvores detectadas não foi aplicado o fator de correção por classe, e sim as equações originais.

Os resultados mais próximos foram observados no talhão *Eucalyptus*, em que o volume total foi superestimado ou subestimado entre -0,05% e 5,26%. No talhão *Pinus* 1 foi observada superestimativa do volume total em todas as equações, variando entre -4,73% e -6,99%. No talhão *Pinus* 2, foram observados os valores mais discrepantes, em que o volume total foi subestimado em todas as equações, com diferença entre 5,64% e 9,09% do volume total.

4.5 DISCUSSÃO

A estimativa de variáveis dendrométricas de dap, altura e volume de árvores individuais a partir de dados de sensores passivos embarcados em plataforma VANT mostrou-se possível, porém com resultados influenciados por parâmetros que expressam as condições da floresta e das variáveis explicativas selecionadas, assim como observados em outros estudos com dados de sensores passivos embarcados em VANT (DANDOIS; ELLIS, 2013; OTA et al., 2017). Essas condições referem-se, por exemplo, à densidade e idade da floresta e configurações do terreno. Entre os talhões, observa-se que as melhores estimativas, para as três variáveis selecionadas, foram obtidas no talhão *Eucalyptus*, seguido pelo talhão de pinus com 7 anos de idade (*Pinus* 2), enquanto que os piores resultados estimativos foram encontrados no talhão de *Pinus* com 16 anos de idade (*Pinus* 1). Ambos os talhões *Eucalyptus* e *Pinus* 2

apresentaram resultados de R^2_{aj} acima de 0,5 com as melhores variáveis, enquanto que no talhão *Pinus* 1, a melhor estimativa encontrada para o volume atingiu R^2_{aj} de 0,37.

Os piores resultados estimativos no talhão *Pinus* 1 podem estar relacionados a diversos fatores, entre eles ao fechamento da copa do talhão, fator que já foi observado como importante na qualidade de estimativas com dados LiDAR (KWAK et al., 2010), pois apesar desse talhão apresentar maior espaçamento de plantio se comparado ao talhão *Pinus* 2, apresenta árvores em idade adulta, portanto com as copas mais fechadas. Apesar disso, acredita-se que a maior causa de problemas pode estar relacionada às condições do talhão, que, conforme destacado anteriormente, apresenta diversas árvores com copas danificadas devido ao ataque do macaco-prego, conforme observado em campo. Esses danos nas copas em muitos casos favorecem o desenvolvimento de copas de árvores vizinhas sobre a árvore atacada, tornando possível, em muitos casos, que a informação espectral e estrutural extraída em nível de copa esteja mesclada com árvores circundantes. Essas árvores danificadas apresentam ainda padrões dendrométricos distintos das árvores normais e têm seu crescimento prejudicado por fatores como tipo de dado e idade em que o ataque ocorreu (LIEBSCH et al., 2015). Nos dados de campo, por exemplo, observou-se que esse talhão apresentava a maior amplitude de dados tanto de dap como de altura, apresentando, em ambos os casos, valores mínimos próximos aos observados no talhão de *Pinus* com 7 anos de idade.

Dentre as variáveis estimadas, observa-se que o volume é a que apresentou os melhores valores de R^2_{aj} , porém com os maiores erros relativos (dados pelo $Syx\%$). Os erros das equações de volume atingiram valores acima de 30% em ambos os talhões de *Pinus* e em torno de 20% no talhão *Eucalyptus*. No talhão *Eucalyptus* e no talhão *Pinus* 2, as equações para a variável altura apresentaram os piores resultados, enquanto que no talhão *Pinus* 1 as equações para dap apresentaram as piores estimativas, ressaltando que nesse talhão é possível que as métricas VANT (extraídas no topo das copas) não refletiam a real situação das árvores devido aos danos.

Os resultados encontrados neste trabalho para dap, entre 0,58 e 0,55, sem e com o uso do fator de correção, podem ser comparados com as estimativas de diâmetro de copa entre 0,63 e 0,85 em floresta temperada mista de coníferas (PANAGIOTIDIS et al., 2016), e 0,79 para estimativa de dap em um plantio de *Pinus*

pinea com amplo espaçamento (GUERRA-HERNÁNDEZ et al., 2017), ambos a partir de dados VANT com sensores passivos. Ainda, os resultados são similares à estimativas de dap a partir de dados LiDAR, podendo-se citar valores de $R^2_{aj.}$ e $Syx\%$ variando entre 0,43 e 0,81 e 3,41% e 8,99%, respectivamente, em plantio de *Pinus taeda* com 40 anos de idade (ZANDONÁ; LINGNAU; NAKAJIMA, 2008). Apesar de os resultados encontrados neste trabalho serem ligeiramente inferiores quando não utilizado o fator de correção (ou seja, as equações originais), são justificados pela sobreposição de copas devido à alta densidade dos talhões.

Quanto as equações para estimativa de altura, os melhores resultados apresentaram $R^2_{aj.}$ de 0,52 nas equações originais, e de 0,75 quando utilizado o fator de correção. Comparativamente, observam-se ajustes com $R^2_{aj.}$ de 0,68 em *Eucalyptus* nativos na Austrália (WALLACE et al., 2016), entre 0,72 e 0,75 em floresta temperada mista de coníferas (PANAGIOTIDIS et al., 2016), 0,71 em floresta conífera temperada (BONNET; LISEIN; LEJEUNE, 2017), e 0,96 em talhão de *Pinus* com amplo espaçamento (GUERRA-HERNÁNDEZ et al., 2017), em nível de árvore individual e dados VANT com sensores passivos. Para modelos em nível de área com uso de sensores passivos em VANT, observam-se valores variando entre 0,07-0,84 de acordo com o tipo florestal, para estimativas das cinco árvores mais altas em florestas decíduas (DANDOIS; ELLIS, 2013), e 0,97 para estimativa de árvore dominante em floresta conífera temperada (PULITI et al., 2015). As estimativas de altura com dados passivos de VANT porém tendem apresentar resultados inferiores se comparadas com estimativas a partir de dados LiDAR, como observado por Dandois e Ellis (2013) e Wallace et al. (2016). Quanto a dados LiDAR, por exemplo, valores de $R^2_{aj.}$ muito altos foram encontrados variando, por exemplo, entre 0,93 e 0,95 para altura média em plantios de *Pinus taeda* em nível de área (SILVA et al., 2017b). De maneira geral, as incertezas nas estimativas de altura com dados VANT podem estar relacionados à suavização das alturas em CHMs, derivados de imagens (BONNET; LISEIN; LEJEUNE, 2017; LISEIN et al., 2013), assim como a problemas na exatidão do modelo de terreno utilizado, pois esse exerce importante efeito nas estimativas (OTA et al., 2015).

As equações estimativas de volume, por sua vez, cujos resultados foram os mais promissores em termos de $R^2_{aj.}$, de até 0,59 e 0,76 nas equações sem e com a inclusão do fator de correção, respectivamente. Ota et al. (2017) observaram modelos de volume médio do talhão com erros variando entre 49-19%, em comparação à altura

média entre 27-6%, também com VANT e sensor passivo. A partir de combinação de métricas de altura, densidade de pontos e médias de bandas espectrais, Puliti et al. (2015) encontraram valores de $R^2_{aj.}$ e RMSE de 0,60 e 38.3 m³/ha para estimativa de volume em floresta de coníferas com VANT e sensor passivo. Ainda, mesmo para modelos estimativos baseados em dados LiDAR, foram observados valores de $R^2_{aj.}$ para modelos estimativos de volume variando entre 0,43 e 0,57, dependendo da densidade da floresta (KWAK et al., 2010), em diversas espécies de *Pinus*.

De maneira geral, a escolha entre as câmeras disponíveis não causou impacto, tanto positivo como negativo, nas estimativas, se comparado à seleção dos tipos de variáveis e dos talhões. Apesar disso, observa-se que, na grande maioria dos casos, os resultados foram ligeiramente superiores com os dados derivados da câmera NIR, com exceção das equações para o talhão *Pinus* 1, que, em todos os casos, a melhor equação foi obtido com a câmera Multi. É possível que em caso como o apresentado nesse talhão, em que existam danos nas árvores, as bandas espectrais disponíveis na câmera Multi e os índices de vegetação forneçam informações adicionais que permitam uma melhor modelagem da situação das árvores. Apesar de se esperar que as câmeras com bandas espectrais como Red-edge e NIR sejam mais eficientes na caracterização da vegetação, esse padrão nem sempre é observado em câmeras acopladas em VANT, como observado por Lisein et al. (2015), que observaram melhor classificação de espécies com câmera RGB, comparada a uma câmera NIR.

Dentre as sete configurações de cenários analisadas, observou-se que em todos os casos os melhores resultados de ajuste foram encontrados a partir da equação que tinha como entrada todas as variáveis disponíveis. Na maioria dos casos, a segunda melhor equação selecionada foi a que combinava variáveis de textura derivadas de produtos espectrais e estruturais e, em alguns poucos casos, a combinação entre as variáveis diretamente extraídas dos produtos espectrais e estruturais foi a segunda melhor combinação. Independentemente das variáveis derivadas diretamente, ou das variáveis de textura, observa-se que as equações que combinam dois tipos de variáveis (uma relacionada aos produtos espectrais e outra aos estruturais), tendem a apresentar melhores resultados. Similar padrão foi observado em estudos combinando dados LiDAR e de imagens para estimativas de volume com melhorias nas estimativas com a combinação de variáveis de ambos sensores (SHINZATO et al., 2017) e para estimativa de biomassa em plantio de álamo

utilizando a combinação das métricas NDVI e altura, se comparado ao uso das duas independentemente (PEÑA et al., 2018)

Apesar de apresentarem ajuste inferior aos das equações que utilizam diferentes tipos de variáveis, as equações com apenas um tipo de variável também apresentam bom ajuste em alguns casos. As melhores equações, envolvendo um só tipo de variável, normalmente foram as que relacionam as variáveis de textura derivadas de produtos estruturais, atingindo valores de R^2_{aj} acima de 0,4, principalmente para as equações estimativas de altura e volume. Mesmo padrão, relativo a estimativa de diâmetro, considerando a utilização de variáveis estruturais e espectrais foi observado por Saarinen et al. (2018), quando detectaram melhor estimativa dessa variável dendrométrica a partir da métrica altura máxima. Ainda, pode-se observar que a utilização das métricas de textura melhoram as estimativas, se comparadas às variáveis destas equações com aquelas derivadas dos produtos estruturais e espectrais originais, em praticamente todos os casos. As equações que apresentavam como variáveis de entrada somente métricas espectrais, principalmente as derivadas dos produtos originais, apresentaram os piores resultados na maioria dos casos, assim como observado por Ota et al. (2017). Dessa forma, observou-se que as métricas espectrais podem auxiliar na estimativa de variáveis dendrométricas, porém, em geral, devem ser combinadas com métricas derivadas de produtos estruturais, como CHM ou MDS.

Até o momento, somente no trabalho de Giannetti et al. (2018) foi testada a utilização de métricas de textura GLCM derivadas de um MDS obtido por imagens de plataforma VANT e observaram que a média da textura homogeneidade foi uma variável independente significativa na estimativa do crescimento volumétrico em floresta mista temperada. Por outro lado, métricas de textura são utilizadas com maior frequência em dados de imagens de satélite e de sensores radar para classificações (LI et al., 2011; VIEIRA et al., 2012) e estimativas de parâmetros da floresta, como biomassa, índice de área foliar, volume e outros (CUTLER et al., 2012; OZDEMIR; KARNIELI, 2011; WIJAYA et al., 2010). Apesar de métricas de textura serem muito úteis, a combinação dessas com variáveis espectrais pode fornecer melhores estimativas do que usadas isoladamente, como observado pela combinação de texturas SAR e bandas do sensor Landsat (4 e 5) para estimativa de biomassa acima do solo em regiões tropicais (CUTLER et al., 2012). Dentre as métricas de textura GLCM disponíveis, em geral pode-se observar que a homogeneidade é uma das mais

importantes e selecionada como explicativa de diversos parâmetros (GIANNETTI et al., 2018), e também selecionada em muitas das equações deste estudo.

Dada a ampla quantidade e variáveis disponíveis, e o grande número de variáveis selecionado no método *stepwise* em todos os casos, não existe clara definição de quais variáveis são as mais importantes, pois muitas foram selecionadas. De maneira geral, porém, observa-se que em todos os casos as equações em que as variáveis estruturais (originais ou derivadas de textura) estavam disponíveis, essas eram selecionadas, em geral, combinando métricas derivada do CHM e do MDS. A única variável estrutural normalmente não selecionada foi a da área de copa, possivelmente devido à baixa relação entre diâmetro de copa e dap (VAUHKONEN et al., 2014), ou aos problemas para a delimitação das copas no processo utilizado.

Pela análise dos gráficos de resíduos, em todas as situações, observou-se que os maiores erros foram encontrados nas menores árvores, fato que pode estar relacionado à sobreposição dessas por árvores vizinhas. Como essa tendência se dá de forma similar em todos as equações e variáveis, é possível minimizá-la pela inclusão de um parâmetro corretivo, como o fator de correção apresentado neste estudo. A inclusão do fator de correção, calculado em classes, permite reduzir tanto as superestimativa como as subestimativas, aplicando um valor adequado para cada classe. Dessa forma, os valores do fator de correção são inferiores a 1 nas menores classes, e superiores a 1 nas maiores classes, tornando os valores das estimativas menores e maiores, respectivamente, para as primeiras e ultimas classes.

Ainda em relação aos erros nas menores árvores, Saarinen et al. (2018) sugerem que, para uma melhor caracterização dessas árvores, sejam utilizados métodos baseados em técnicas semi-individuais (ou mistas), em que se calculam métricas em nível de área e o número de árvores detectadas (para cada área considerada) é incluído como variável explicativa. Nesses casos os parâmetros de heterogeneidade (variância de altura por exemplo), caracterizarão a presença de árvores menores.

Apesar dos elevados erros obtidos com essas árvores em termos relativos, a contribuição dessas no volume total do talhão é muito pequena, de forma que esses erros não são considerados como relevantes. Como no presente estudo foram utilizados dados de censo sem limite mínimo de dap ou altura, árvores muito pequenas foram utilizadas nas equações, porém essas não são consideradas em levantamentos volumétricos tradicionais, em que normalmente considera-se um dap mínimo. Ainda,

na prática, espera-se que estimativas de variáveis dendrométricas sejam efetuadas utilizando-se dados derivados de árvores detectadas automaticamente e, nesses casos, observa-se que as árvores suprimidas tendem a não ser detectadas (VAUHKONEN et al., 2014).

A qualidade das estimativas dendrométricas em nível de árvore individual não é dependente somente da construção de modelos que relacionam eficientemente as variáveis dependentes e independentes, mas também da detecção das árvores (VAUHKONEN et al., 2014; YU et al., 2010). Com relação a esse fator, as estimativas totais de volume dos talhões, com base nas árvores detectadas no Capítulo 3 foram efetuadas e resultados foram muito próximos ao volume total obtido pelo censo florestal. Os erros de estimativa de volume total foram, em todos os casos, menores do que 10% do volume do talhão, independentemente da equação utilizada. Observou-se que nos talhões em que houve subestimativa do número total de árvores, houve também subestimativa do volume, enquanto que, no único talhão no qual se detectou um número de árvores maior que o real, o volume total foi superestimado também, destacando mais uma vez a necessidade da correta detecção de árvores para modelos estimativos baseados em árvore individual. Como em todos os casos a detecção foi próxima ao número real de árvores, os volumes estimados totais também foram muito próximos.

4.6 CONCLUSÕES

É possível a construção de equações estimativas de dap, altura e volume a partir de dados de sensores passivos embarcados em VANT. A qualidade do ajuste das equações estimativas foi variável conforme as condições ou características dos talhões e dos tipos de variáveis disponíveis.

O talhão de *Eucalyptus* apresentou os melhores resultados estimativos para todas as variáveis, seguido pelo talhão de *Pinus* mais jovem. O talhão de *Pinus* com maior idade apresentou os piores resultados. Dentre as variáveis, observou-se que a combinação entre variáveis espectrais, estruturais e de textura GLCM apresentou as melhores equações estimativas para todas as variáveis, nos três talhões analisados. A seleção de diferentes câmeras passivas foi o fator que apresentou menor influência na qualidade das estimativas, apesar de que as equações derivadas da câmera NIR terem gerado os melhores resultados na maioria dos casos.

A utilização de um fator de correção por classe de dap, altura e volume permitiu melhoria nas estimativas e reduziu as tendências de superestimativa dos valores nas menores árvores, e subestimativa nas maiores, observadas em todas as equações.

A aplicação das equações estimativas de volume, sem inclusão do fator de correção, em dados de árvores individuais automaticamente detectadas demonstrou que a estimativa do volume total dos talhões é muito próxima daquela obtida pelo censo.

Sugere-se que trabalhos futuros utilizem um valor mínimo de tamanho para que as árvores sejam consideradas no inventário ou censo, pois as pequenas árvores apresentaram erros altos e correspondem a uma parcela muito pequena do volume do talhão. Ainda, seria interessante em trabalhos futuros a realização dos ajustes de volume com base em dados de cubagem realizados em campo, excluindo assim possíveis erros inerentes de equações de volume já ajustadas. Também se recomenda que trabalhos futuros avaliem outros métodos de ajustes para as estimativas de dap, altura e volume, como métodos não lineares ou técnicas de aprendizado de máquina. Por fim, os métodos aplicados neste trabalho podem ser validados em outras situações, como diferentes tipos de florestas (nativas ou plantadas em diferentes condições), assim como com diferentes sensores.

CONCLUSÃO GERAL E RECOMENDAÇÕES

Dado todo o processamento de dados e extração de variáveis de interesse em inventário florestal por meio de dados coletados com plataforma VANT embarcada com sensores passivos, pode-se concluir que:

- O sistema VANT com as configurações de voo selecionadas permitiu a obtenção de produtos caracterizando a área de estudo com alta resolução e adequada exatidão posicional;
- O desenvolvimento de uma ferramenta para detecção de árvores individuais a partir de arquivos derivados de VANT de forma semi-automatizada foi possível com ótimos resultados, principalmente quando foi aplicada utilizando uma banda espectral como entrada para o processo, em comparação ao seu uso com um CHM;
- Métodos e ferramentas de detecção de árvores originalmente desenvolvidos para LiDAR podem ser aplicados em CHM derivados de dados VANT, porém sua capacidade de detecção é altamente influenciada pelas condições dos talhões e a disponibilidade de um MDT para normalização das alturas;
- É possível a estimativa das variáveis dendrométricas dap, altura e volume a partir de métricas derivadas dos produtos VANT, com resultados de ajuste bons em talhões em condições homogêneas (sem muitos defeitos);
- As estimativas das variáveis dendrométricas com VANT tendem a subestimar árvores maiores e principalmente superestimar árvores pequenas, porém estas geralmente não são detectadas em algoritmos detecção automática de árvores, e, portanto, não causam grande influência no volume total do talhão;
- O uso de um fator de correção para corrigir as estimativas de dap, altura e volume, desenvolvido por classes de tamanho, permitiu melhorias no ajuste das equações e diminuição substancial das tendências observadas.

Da mesma forma, para trabalhos futuros sugere-se que:

- O efeito de parâmetros de voo como altitude, padrões de iluminação e ângulos de visada sejam avaliados com relação aos seus efeitos na detecção de árvores e estimativas dendrométricas;

- Modelos mistos (semi-individuais) de estimativas de variáveis dendrométricas a partir de dados VANT sejam avaliados, combinando o total de árvores detectadas com métricas derivadas em nível de parcelas.

REFERÊNCIAS

ADÃO, T. et al. Hyperspectral imaging: a review on UAV-based sensors, data processing and applications for agriculture and forestry. **Remote Sensing**, v. 9, n. 11, p. 1–30, 2017.

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (ANAC). **Cadastro de Drones**. 2017b. Disponível em: <<http://www.anac.gov.br/assuntos/paginas-tematicas/drones/cadastro-de-drones>>. Acesso em: 7 mar. 2018.

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (ANAC). **Quantidade de Cadastros**. 2018. Disponível em: <<http://www.anac.gov.br/assuntos/paginas-tematicas/drones/quantidade-de-cadastros>>. Acesso em: 7 mar. 2018.

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (ANAC). Resolução nº 143, de 17 de março de 2010. Certificação de Produto Aeronáutico - RBAC nº 21, emenda nº 2. **Diário Oficial da União**, Brasília, 22 de out. 2015.

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (ANAC). Resolução Nº 293, de 19 de Novembro de 2013. Dispõe sobre o Registro Aeronáutico Brasileiro e dá outras providências. **Diário Oficial da União**, Brasília, n. 228, 25 de nov. 2013.

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (ANAC). Resolução nº 419, de 2 de maio de 2017. Requisitos Gerais para Aeronaves Não Tripuladas de Uso Civil. **Diário Oficial da União**, Brasília, 3 maio. 2017a.

AGÊNCIA NACIONAL DE TELECOMUNICAÇÕES (ANATEL). **Manual de Orientações**. Homologação de DRONES. Uso próprio/pessoal - Declaração de Conformidade. 2018. Disponível em: <<http://www.anatel.gov.br/Portal/verificaDocumentos/documento.asp?numeroPublicacao=347942&filtro=1&documentoPath=347942.pdf>>. Acesso em: 15 mar. 2018.

AGÊNCIA NACIONAL DE TELECOMUNICAÇÕES (ANATEL). **Produtos homologados: Drones devem ser homologados para evitar interferências**. 2016. Disponível em: <<http://www.anatel.gov.br/institucional/component/content/article/2-uncategorised/1485-drones-devem-ser-homologados-para-evitar-interferencias?Itemid=126>>. Acesso em: 15 mar. 2018.

AGISOFT LLC. **Agisoft PhotoScan Change Log**. 2018. Disponível em: <http://www.agisoft.com/pdf/photoscan_changelog.pdf>. Acesso em: 9 maio. 2018.

AGÜERA-VEGA, F.; CARVAJAL-RAMÍREZ, F.; MARTÍNEZ-CARRICONDO, P. Assessment of photogrammetric mapping accuracy based on variation ground control points number using unmanned aerial vehicle. **Measurement**, v. 98, p. 221–227, 2017.

ALONZO, M. et al. Quantifying boreal forest structure and composition using UAV structure from motion. **Forests**, v. 9, n. 3, , p. 1–15, 2018.

AMIREBRAHIMI, S. et al. UAV Data Acquisition, Australia and New Zealand: **User needs report**. Carlton South, 2018.

ANDERSON, K.; GASTON, K. J. Lightweight unmanned aerial vehicles will revolutionize spatial ecology. **Frontiers in Ecology and the Environment**, v. 11, n. 3, p. 138–146, 2013.

ANDRADE, J. B. **Fotogrametria**. 2 ed. Curitiba: SBEE, 2003.

ANSCOMBE, F. J. Graphs in Statistical Analysis. **The American Statistician**, v. 27, n. 1, p. 17–21, 1973.

ARCGIS. **How Flow Direction works**. 2017 Disponível em: <<http://pro.arcgis.com/en/pro-app/tool-reference/spatial-analyst/how-flow-direction-works.htm>>. Acesso em: 1 jan. 2017.

ARMSTON, J. **RSC LAS Tools**, versão 1.9.3. 2012. Disponível em: <<https://code.google.com/archive/p/rsclastools/>>. Acesso em: 8 jun. 2018.

AYREY, E. et al. Layer Stacking: A novel algorithm for individual forest tree segmentation from LiDAR point clouds. **Canadian Journal of Remote Sensing**, v. 43, n. 1, p. 16–27, 2017.

BAENA, S. et al. Identifying species from the air: UAVs and the very high resolution challenge for plant conservation. **PLoS ONE**, v. 12, n. 11, p. 1–21, 2017.

BALDAUF, T.; GARCIA, M. Image processing of radar and Lidar in tropical forestry. In: PANCEL, L.; KÖHL, M. (Eds.). **Tropical Forestry Handbook**. 1. ed. Berlin: Springer-Verlag Berlin Heidelberg, 2016. p. 635–661.

BALDRATI, A. C. M. **Estudo comparativo do crescimento de quatro espécies de *Eucalyptus* spp. (Myrtaceae) na região de Jaguariaíva/PR**. 38 f. Trabalho de Conclusão de Curso (Programa de Educação Continuada em Ciências Agrárias) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2015.

BARKÓCZI, N. et al. Examples from the boundaries of geographic survey: architecture and flood modeling. In: CASAGRANDE, G.; SIK, A.; SZABO, G. (Eds.). **Small flying drones: applications for geographic observation**. Springer, 2018. p. 127–157.

BEARD, R. W.; MCLAIN, T. W. **Small Unmanned Aircraft: theory and practice**. Princeton: Princeton University Press, 2012.

BEMIS, S. P. et al. Ground-based and UAV-Based photogrammetry: A multi-scale, high-resolution mapping tool for structural geology and paleoseismology. **Journal of Structural Geology**, v. 69, p. 163–178, 2014.

BIRDAL, A. C.; AVDAN, U.; TÜRK, T. Estimating tree heights with images from an unmanned aerial vehicle. **Geomatics, Natural Hazards and Risk**, v. 8, n. 2, p. 1144–1156, 2017.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p. 2–16, 2010.

BOLDRINI, I. I. A flora dos campos do Rio Grande do Sul. In: PILLAR, V. de P. (Eds.). **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília: MMA, 2009. p. 63–77.

BONHAM, C. D. **Measurements for Terrestrial Vegetation Measurements**. 1. ed. Oxford: John Wiley & Sons, Ltd, 2013.

BONNET, S.; LISEIN, J.; LEJEUNE, P. Comparison of UAS photogrammetric products for tree detection and characterization of coniferous stands detection and characterization of coniferous stands. **International Journal of Remote Sensing**, v. 38, n. 19, p. 5310–5337, 2017.

BREDE, B. et al. Comparing RIEGL RiCOPTER UAV LiDAR derived canopy height and DBH with terrestrial LiDAR. **Sensors**, v. 17, n. 10, p. 1–16, 2017.

BROVKINA, O. et al. Unmanned aerial vehicles (UAV) for assessment of qualitative classification of Norway spruce in temperate forest stands. **Geo-Spatial Information Science**, v. 21, n. 1, p. 12–20, 2018.

BRYSON, M. PointcloudITD: A software package for individual tree detection and counting. In: STONE, C.; OSBORN, J. (Eds.). **Deployment and integration of cost-effective high resolution remotely sensed data for the Australian forest industry**. Melbourne: Forest & Wood Products Australia, 2017. p. 154–172.

CARRIVICK, J. L.; SMITH, M. W.; QUINCEY, D. J. **Structure from motion in the geosciences**. West Sussex: John Wiley & Sons, Ltd, 2016.

CHABOT, D.; BIRD, D. M. Wildlife research and management methods in the 21st century: Where do unmanned aircraft fit in? **Journal of Unmanned Vehicle Systems**, v. 3, n. 4, p. 137–155, 2015.

CHAO, H.; CHEN, Y. **Remote Sensing and Actuation Using Unmanned Vehicles**. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2012.

CHIANUCCI, F. et al. Estimation of canopy attributes in beech forests using true colour digital images from a small fixed-wing UAV. **International Journal of Applied Earth Observation and Geoinformation**, v. 47, p. 60–68, 2016.

COCHRAN, W. G. **Sampling Techniques**. 3. ed. New York: John Wiley & Sons, Inc., 1977.

COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79–97, 2014.

CUNLIFFE, A. M.; BRAZIER, R. E.; ANDERSON, K. Ultra-fine grain landscape-scale quantification of dryland vegetation structure with drone-acquired structure-from-motion photogrammetry. **Remote Sensing of Environment**, v. 183, p. 129–143, 2016.

CUTLER, M. E. J. et al. Estimating tropical forest biomass with a combination of SAR image texture and Landsat TM data: an assessment of predictions between regions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 70, p. 66–77, 2012.

DALAMAGKIDIS, K. Aviation History and Unmanned Flight. In: VALAVANIS, K. P.; VACHTSEVANOS, G. J. (Eds.). **Handbook of Unmanned Aerial Vehicles**. Dordrecht: Springer, 2015a. p. 57–81.

DALAMAGKIDIS, K. Classification of UAVs. In: VALAVANIS, K. P.; VACHTSEVANOS, G. J. (Eds.). **Handbook of Unmanned Aerial Vehicles**. Dordrecht: Springer, 2015b. p. 83–90.

DALMOLIN, Q.; SANTOS, D. R. **Sistema Laser scanner: Conceitos e Princípios de Funcionamento**. 3. ed. Curitiba: UFPR, 2004.

DANDOIS, J. P.; ELLIS, E. C. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. **Remote Sensing of Environment**, v. 136, p. 259–276, 2013.

DANDOIS, J. P.; OLANO, M.; ELLIS, E. C. Optimal altitude, overlap, and weather conditions for computer vision uav estimates of forest structure. **Remote Sensing**, v. 7, n. 10, p. 13895–13920, 2015.

DASH, J. P. et al. Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease outbreak. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 131, p. 1–14, 2017.

DASSOT, M.; CONSTANT, T.; FOURNIER, M. The use of terrestrial LiDAR technology in forest science: application fields, benefits and challenges. **Annals of Forest Science**, v. 68, n. 5, p. 959–974, 2011.

DEMPEWOLF, J. et al. Measurement of within-season tree height growth in a mixed forest stand using UAV imagery. **Forests**, v. 8, n. 7, p. 1–15, 2017.

DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO (DECEA). ICA 100-12. Regras do Ar. 2016b. **Boletim do Comando da Aeronáutica**, nº 182, 24 out. 2016.

DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO (DECEA). ICA 100-37. Serviços de Tráfego Aéreo. 2017a. **Boletim do Comando da Aeronáutica**, nº 213, 12 dez. 2017.

DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO (DECEA). ICA 100-40. Sistemas de Aeronaves Remotamente Pilotadas e o Acesso ao Espaço Aéreo Brasileiro. 2016a. **Boletim do Comando da Aeronáutica**, nº 019, 2 fev. 2017.

DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO (DECEA). MCA 100-11. Preenchimento dos Formulários de Plano de Voo. 2017b. **Boletim do Comando da Aeronáutica**, nº 125, 24 jul. 2017.

DRAPER, N. R.; SMITH, H. **Applied Regression Analysis**. 3. ed. New York: John Wiley & Sons, Inc., 1998.

DRONE DEPLOY. **DroneDeploy's 2017 Drone Buyer's Guide**. 2017. Disponível em: <<https://www.dronedeploy.com/resources/ebooks/2017-drone-buyers-guide/>>. Acesso em: 9 maio. 2018.

DRONES MADE EASY. **Terrain awareness**. 2018. Disponível em: <<https://support.dronesmadeeasy.com/hc/en-us/articles/211810943-Terrain-Awareness>>. Acesso em: 9 maio. 2018.

DURRIEU, S. et al. Optical Remote Sensing of Tree and Stand Heights. In: THENKABAIL, P. S. (Ed.). **Land Resources Monitoring, Modeling, and Mapping with Remote Sensing**. Boca Raton: CRC Press, 2015. p. 449–485.

EISENBEISS, H.; SAUERBIER, M. Investigation of UAV systems and flight modes for photogrammetric applications. **Photogrammetric Record**, v. 26, n. 136, p. 400–421, 2011.

ELKAIM, G. H.; LIE, F. A. P.; GEBRE-EGZIABHER, D. Principles of guidance, navigation, and control of UAVs. In: VALAVANIS, K. P.; VACHTSEVANOS, G. J. (Eds.). **Handbook of Unmanned Aerial Vehicles**. Dordrecht: Springer, 2015. p. 347–380.

ELTNER, A. et al. Image-based surface reconstruction in geomorphometry-merits, limits and developments. **Earth Surface Dynamics**, v. 4, n. 2, p. 359–389, 2016.

ELTNER, A.; SCHNEIDER, D. Analysis of Different Methods for 3D Reconstruction of Natural Surfaces from Parallel-Axes UAV Images. **Photogrammetric Record**, v. 30, n. 151, p. 279–299, 2015.

FAHLSTROM, P. G.; GLEASON, T. J. **Introduction to UAV Systems**. 4^a ed. West Sussex: John Wiley & Sons, Incorporated, 2012.

FAVORSKAYA, M. N.; JAIN, L. C. **Handbook on Advances in Remote Sensing and Geographic Information Systems Paradigms and Applications in Forest Landscape Modeling**. Boca Raton: CRC Press, 2017.

FEDERAL AVIATION ADMINISTRATION (FAA). **Part 107 - Small Unmanned Aircraft Systems**, 2016. Disponível em: <<https://www.ecfr.gov/cgi-bin/retrieveECFR?gp=1&SID=dcf7ddb5f58f33726d33d7bc50a36d72&ty=HTML&h=L&mc=true&r=PART&n=pt14.2.107>>. Acesso em: 9 maio. 2018.

FERNÁNDEZ-GUISURAGA, J. M. et al. Using unmanned aerial vehicles in postfire vegetation survey campaigns through large and heterogeneous areas: Opportunities and challenges. **Sensors**, v. 18, n. 2, p. 2–17, 2018.

FLOREANO, D.; WOOD, R. J. Science, technology and the future of small autonomous drones. **Nature**, v. 521, n. 7553, p. 460–466, 2015.

FRANKLIN, S. E.; AHMED, O. S. Deciduous tree species classification using object-based analysis and machine learning with unmanned aerial vehicle multispectral data. **International Journal of Remote Sensing**, UAS Special issue, p. 5236–5245, 2017.

GARCIA-RUIZ, F. et al. Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. **Computers and Electronics in Agriculture**, v. 91, p. 106–115, 2013.

GAŠPAROVIĆ, M. et al. The evaluation of photogrammetry-based DSM from low-cost UAV by LiDAR-based DSM. **South-east European forestry**, v. 8, n. 2, p. 117–125, 2017.

GENS, R. Spectral information content of remote sensing imagery. In: DEREN LI; SHAN, J.; GONG, J. (Eds.). **Geospatial technology for earth observation** Berlin: Springer, 2009. p. 177–202.

GERKE, M.; PRZYBILLA, H.-J. Accuracy analysis of photogrammetric UAV image blocks: influence of onboard RTK-GNSS and cross flight patterns. **Photogrammetrie**, v. 2016, n. 1, p. 17–30, 2016.

GETZIN, S.; NUSKE, R. S.; WIEGAND, K. Using unmanned aerial vehicles (UAV) to quantify spatial gap patterns in forests. **Remote Sensing**, v. 6, n. 8, p. 6988–7004, 2014.

GIANNETTI, F. et al. A new set of DTM-independent metrics for forest growing stock prediction using UAV photogrammetric data. **Remote Sensing of Environment**, v. 213, p. 195–205, 2018.

GIORDAN, D. et al. Review article: The use of remotely piloted aircraft systems (RPAS) for natural hazards monitoring and management. **Natural Hazards and Earth System Sciences Discussions**, v. 18, p. 1079–1096, 2018.

GOODBODY, T. R. H. et al. Unmanned aerial systems for precision forest inventory purposes: A review and case study. **The Forestry Chronicle**, v. 93, n. 01, p. 71–81, 2017.

GRANSHAW, S. I. Photogrammetric Terminology: Third Edition. **Photogrammetric Record**, v. 31, n. 154, p. 210–252, 2016.

GUERRA-HERNÁNDEZ, J. et al. Comparison of ALS- and UAV(SfM)-derived high-density point clouds for individual tree detection in *Eucalyptus* plantations. **International Journal of Remote Sensing**, v. 39, n. 15-16, p. 5211-5235, 2018.

GUERRA-HERNÁNDEZ, J. et al. Use of Multi-Temporal UAV-Derived Imagery for Estimating Individual Tree Growth in *Pinus pinea* Stands. **Forests**, v. 8, n. 8, p. 1–19, 2017.

GUERRA-HERNÁNDEZ, J. et al. Using high resolution UAV imagery to estimate tree variables in *Pinus pinea* plantation in Portugal. **Forest Systems**, v. 25, n. 2, 2016.

GUJARATI, D. N.; PORTER, D. C. **Basic Econometrics**. 5. ed. New York: The McGraw-Hill Companies, Inc, 2008.

HANSEN, E. H.; GOBAKKEN, T.; NÆSSET, E. Effects of pulse density on digital terrain models and canopy metrics using airborne laser scanning in a tropical rainforest. **Remote Sensing**, v. 7, n. 7, p. 8453–8468, 2015.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on systems, mas and cybernetics**, v. SMC-3, n. 6, p. 610–621, 1973.

HELMER, E. H. et al. Characterizing Tropical Forests with Multispectral Imagery. In: THENKABAIL, P. S. (Ed.). **Land Resources Monitoring, Modeling, and Mapping with Remote Sensing**. Boca Raton: CRC Press, 2015. p. 367–396.

HENTZ, Â. M. K. et al. Treedetection: Automatic tree detection using UAV-based data. **Floresta**, Curitiba, v. 48, n. 3, p. 393–402, 2018.

HIGUCHI, N.; SANTOS, J.; JARDIM, F. C. S. Tamanho de parcela amostral para inventários florestais. **Acta Amazonica**, Manaus, v. 12, n. 1, p. 91–103, 1982.

HUANG, H.; LI, X.; CHEN, C. Individual tree crown detection and delineation from very-high-resolution UAV images based on bias field and marker-controlled watershed segmentation algorithms. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, p. 1–10, 2018.

HYPPÄ, J. et al. Remote sensing of forests from LiDAR and Radar. In: THENKABAIL, P. S. (Ed.). **Land Resources Monitoring, Modeling, and Mapping with Remote Sensing**. Boca Raton, USA: CRC Press, 2015. p. 397–428.

HYPPÄ, J. et al. Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. **International Journal of Remote Sensing**, v. 29, n. 5, p. 37–41, 2008.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Manual Técnico da Vegetação Brasileira**. Rio de Janeiro: IBGE, 2012.

INSTITUTO DE TERRAS, CARTOGRAFIA E GEOLOGIA DO PARANÁ (ITCG).

Clima: estado do Paraná. Disponível em:

<http://itcg.pr.gov.br/arquivos/File/Produtos_DGEO/Mapas_ITCG/PDF/Mapa_Climas_A3.pdf>. Acesso em: 14 nov. 2017b.

INSTITUTO DE TERRAS, CARTOGRAFIA E GEOLOGIA DO PARANÁ (ITCG).

Formações Fitogeográficas: Estado do Paraná. Disponível em:

<http://www.itcg.pr.gov.br/arquivos/File/Produtos_DGEO/Mapas_ITCG/PDF/Mapa_Fitogeografico_A3.pdf>. Acesso em: 14 nov. 2017.

INSTITUTO DE TERRAS, CARTOGRAFIA E GEOLOGIA DO PARANÁ (ITCG).

Solos: Estado do Paraná. Disponível em:

<http://itcg.pr.gov.br/arquivos/File/Produtos_DGEO/Mapas_ITCG/PDF/Mapa_Solos.pdf>. Acesso em: 14 nov. 2017a.

INSTITUTO PARANAENSE DE DESENVOLVIMENTO ECONÔMICO E SOCIAL (IPARDES). **Leituras regionais: mesorregiões geográficas**. Curitiba: IPARDES, 2004.

INSTITUTO PARANAENSE DE DESENVOLVIMENTO ECONÔMICO E SOCIAL (IPARDES). **Relação dos Municípios do Estado Ordenados Segundo as Mesorregiões e as Microrregiões Geográficas do IBGE: Paraná - 2012**. 2012.

Disponível em:

<http://www.ipardes.gov.br/pdf/mapas/base_fisica/relacao_mun_micros_mesos_parana.pdf>. Acesso em: 1 jan. 2017.

INSTITUTO PARANAENSE DE DESENVOLVIMENTO ECONÔMICO E SOCIAL (IPARDES). **Perfil da Microrregião Geográfica de Telêmaco Borba**. 2017a.

Disponível em:

<http://www.ipardes.gov.br/perfil_municipal/MontaPerfil.php?codlocal=619&btOk=ok>. Acesso em: 1 jan. 2017.

INSTITUTO PARANAENSE DE DESENVOLVIMENTO ECONÔMICO E SOCIAL (IPARDES). **Perfil Avançado do Município de Telêmaco Borba**. 2017b. Disponível em:

<http://www.ipardes.gov.br/perfil_municipal/MontaPerfil.php?codlocal=53&btOk=ok>. Acesso em: 1 jan. 2017.

INTERNATIONAL CIVIL AVIATION ORGANIZATION (ICAO). **Manual on Remotely Piloted Aircraft Systems (RPAS)**. 1. ed. Montréal: International Civil Aviation Organization, 2015.

IQBAL, F.; LUCIEER, A.; BARRY, K. Simplified radiometric calibration for UAS-mounted multispectral sensor. **European Journal of Remote Sensing**, v. 51, n. 1, p. 301–313, 2018.

IQBAL, I. A. et al. Evaluating the robustness of point clouds from small format aerial photography over a *Pinus radiata* plantation. **Australian Forestry**, v. 81, n. 3, p. 162–176, 2018.

JENSEN, J. L. R.; MATHEWS, A. J. Assessment of image-based point cloud products to generate a bare earth surface and estimate canopy heights in a woodland ecosystem. **Remote Sensing**, v. 8, n. 1, 2016.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução de: EPIPHANIO, J. C. N. et al. 2. ed. São José dos Campos: Parêntese, 2009. Título original: Remote Sensing of the Environment: An Earth Resource Perspective.

JORGE, L. A. DE C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão. In: BERNARDI, A. C. DE C. et al. (Eds.). **Agricultura de Precisão: Um Novo Olhar**. São Carlos: Embrapa, 2014. p. 109–134.

KAARTINEN, H. et al. An international comparison of individual tree detection and extraction using airborne laser scanning. **Remote Sensing**, v. 4, n. 4, p. 950–974, 2012.

KARYDAS, C. et al. Olive plantation mapping on a sub-tree scale with object-based image analysis of multispectral UAV data; operational potential in tree stress monitoring. **Journal of Imaging**, v. 3, n. 4, p. 57, 2017.

KATHURIA, A. et al. Development of an automated individual tree detection model using point cloud LiDAR data for accurate tree counts in a *Pinus radiata* plantation. Development of an automated individual tree detection model using point cloud. **Australian Forestry**, v. 79, n. 2, p. 126–136, 2016.

KE, Y.; QUACKENBUSH, L. J. A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. **International Journal of Remote Sensing**, v. 32, n. 17, p. 4725–4747, 2011.

KEDZIERSKI, M.; WIERZBICKI, D. Radiometric quality assessment of images acquired by UAV's in various lighting and weather conditions. **Measurement**, v. 76, p. 156–169, 2015.

KERSHAW JR., J. A. et al. **Forest Mensuration**. 5. ed. West Sussex: John Wiley & Sons, Ltd Registered, 2017.

KOCH, B. Status and future of laser scanning, synthetic aperture radar and hyperspectral remote sensing data for forest biomass assessment. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 6, p. 581–590, 2010.

KOEHLER, A.; FIRKOWSKI, C. Descascamento de *pinus* por *Cebus apella*. **Floresta**, Curitiba, v. 24, n. 1/2, p. 6, 1996.

KOUKOULAS, S.; BLACKBURN, G. A. Mapping individual tree location, height and species in broadleaved deciduous forest using airborne LIDAR and multi-spectral remotely sensed data. **International Journal of Remote Sensing**, v. 26, n. 3, p. 431–455, 2005.

KVALSETH, T. O. Cautionary Note about R^2 . **The American Statistician**, v. 39, n. 4, p. 279–285, 1985.

KWAK, D. A. et al. Estimating stem volume and biomass of *Pinus koraiensis* using LiDAR data. **Journal of Plant Research**, v. 123, n. 4, p. 421–432, 2010.

LAAR, A. VAN; AKÇA, A. **Forest Mensuration**. The Netherlands: Springer, 2007.

LEBOURGEOIS, V. et al. Can commercial digital cameras be used as multispectral sensors? A crop monitoring test. **Sensors**, v. 8, n. 11, p. 7300–7322, 2008.

LECKIE, D. et al. Combined high-density lidar and multispectral imagery for individual tree crown analysis. **Canadian Journal of Remote Sensing**, v. 29, n. 5, p. 633–649, 2003.

LEHMANN, J. R. K. et al. Analysis of unmanned aerial system-based CIR images in forestry-a new perspective to monitor pest infestation levels. **Forests**, v. 6, n. 3, p. 594–612, 2015.

LEITE, H. G.; ANDRADE, V. C. L. DE. Um método para condução de inventários florestais sem o uso de equações volumétricas. **Revista árvore**, Viçosa, v. 26, n. 3, p. 321–328, 2002.

LI, G. et al. Land-cover classification in a moist tropical region of Brazil with Landsat Thematic Mapper imagery. **International Journal of Remote Sensing**, v. 32, n. 23, p. 8207–8230, 2011.

LI, W. et al. A new method for segmenting individual trees from the LiDAR point cloud **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 1, p. 75–84, 2012.

LIANG, X. et al. Terrestrial laser scanning in forest inventories. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 63–77, 2016.

LIEBSCH, D. et al. Descascamento de *Pinus taeda* por macacos-prego (*Sapajus nigritus*): tipos e intensidades de danos e seus impactos sobre o crescimento das árvores. **Scientia Forestalis**, Piracicaba, v. 43, n. 105, p. 37–49, 2015.

LIEBSCH, D. et al. Impacto do descascamento de árvores de *Pinus Taeda* L. por macacos-Prego na produção e receita em plantios. **BIOFIX Scientific Journal**, Curitiba, v. 3, n. 1, p. 48–55, 2018.

LIEBSCH, D.; MIKICH, S. B. Damage caused by brown-capuchin monkeys to nine *pinus* species and the implications for forest management. **Floresta**, Curitiba, v. 47, n. 1, p. 37–42, 2017.

LINDER, W. **Digital Photogrammetry: A Practical Course**. 4. ed. Berlin: Springer, 2016.

LISEIN, J. et al. A photogrammetric workflow for the creation of a forest canopy height model from small unmanned aerial system imagery. **Forests**, v. 4, n. 4, p. 922–944, 2013.

LISEIN, J. et al. Discrimination of deciduous tree species from time series of unmanned aerial system imagery. **PLoS ONE**, v. 10, n. 11, p. 1–20, 2015.

LOUREIRO, G. H. **Redes neurais artificiais e modelos de regressão para estimação de variáveis dendrométricas em *Pinus taeda* L: análise comparativa**. 153 f. Tese (Doutorado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2016.

LOWE, D. G. Distinctive Image Features from Scale-Invariant Keypoints. **International Journal of Computer Vision**, v. 60, n. 2, p. 91–110, 2004.

LU, D.; BATISTELLA, M. Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon. **Acta Amazonica**, v. 35, n. 2, p. 249–257, 2005.

MAACK, R. **Geografia física do estado do Paraná**. Curitiba: Banco de Desenvolvimento do Paraná, 1968.

MALTAMO, M.; NÆSSET, E.; VAUHKONEN, J. **Forestry Applications of Airborne Laser Scanning**. Dordrecht: Springer, 2014.

MANFREDA, S. et al. On the Use of Unmanned Aerial Systems for Environmental Monitoring. **Remote Sensing**, v. 10, n. 4, p. 2–28, 2018.

MCGAUGHEY, R. J. **FUSION/LDV LIDAR analysis and visualization software**, 2018. Disponível em: <http://forsys.cfr.washington.edu/fusion/fusion_overview.html>. Acesso em: 9 maio. 2018.

MEJIAS, L.; LAI, J.; BRUGGEMANN, T. Sensors for Missions. In: VALAVANIS, K. P.; VACHTSEVANOS, G. J. (Eds.). **Handbook of Unmanned Aerial Vehicles**. Dordrecht: Springer, 2015. p. 385–399.

MESSINGER, M.; ASNER, G. P.; SILMAN, M. Rapid assessments of amazon forest structure and biomass using small unmanned aerial systems. **Remote Sensing**, v. 8, n. 8, p. 1–15, 2016.

MICHELETTI, N.; CHANDLER, J. H.; LANE, S. N. Structure from Motion (SfM) Photogrammetry. **British Society for Geomorphology Geomorphological Techniques**, v. 2, n. 2, p. 1–12, 2015.

MIRANDA, R. O. V. DE. **Modelagem de árvores individuais para povoamentos não desbastados de *Pinus taeda* L.** 168 f. Tese (Doutorado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2016.

MLAMBO, R. et al. Structure from motion (SfM) photogrammetry with drone data: A low cost method for monitoring greenhouse gas emissions from forests in developing countries. **Forests**, v. 8, n. 3, 2017.

MOHAN, M. et al. Individual tree detection from unmanned aerial vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest. **Forests**, v. 8, n. 9, p. 340, 2017.

MORGAN, J. L.; GERGEL, S. E.; COOPS, N. C. Aerial photography: a rapidly evolving tool for ecological management. **BioScience**, v. 60, n. 1, p. 47–59, 2010.

MORO, R. S.; CARMO, M. R. B. DO. A vegetação Campestre nos Campos Gerais. In: MORO, M. S. de; SEGECIN, R.; GUIMARÃES, G. B. (Eds.). **Patrimônio Natural do Campos Gerais do Paraná**, Ponta Grossa, PR Ed. UEPG, 2007. p. 93–98.

NADOLINETS, L.; LEVIN, E.; AKHMEDOV, D. **Surveying instruments and technology**. Boca Raton: CRC Press, Taylor & Francis Group, 2017.

NÆSSET, E. Area-Based Inventory in Norway – From innovation to an operational reality. In: MALTAMO, M.; NÆSSET, E.; VAUHKONEN, J. (Eds.). **Forestry Applications of Airborne Laser Scanning: Concepts and Case Studies**. Dordrecht: Springer, 2014. p. 215–240.

NARUMALANI, S.; MERANI, P. Digital image processing: a review of the fundamental methods and techniques. In: THENKABAIL, P. S. (Ed.). **Remotely Sensed data Characterization, Classification, and Accuracies**. Boca Raton, FL: CRC Press, 2015. p. 197–217.

NÄSI, R. et al. Remote sensing of bark beetle damage in urban forests at individual tree level using a novel hyperspectral camera from UAV and aircraft. **Urban Forestry and Urban Greening**, v. 30, p. 72–83, 2018.

NÄSI, R. et al. Using UAV-based photogrammetry and hyperspectral imaging for mapping bark beetle damage at tree-level. **Remote Sensing**, v. 7, n. 11, p. 15467–15493, 2015.

NEVALAINEN, O. et al. Individual tree detection and classification with UAV-Based photogrammetric point clouds and hyperspectral imaging. **Remote Sensing**, v. 9, n. 3, 2017.

NEX, F.; REMONDINO, F. UAV for 3D mapping applications: A review. **Applied Geomatics**, v. 6, n. 1, p. 1–15, 2014.

OLIVEIRA, L. T. de et al. Application of LIDAR to forest inventory for tree count in stands of *Eucalyptus* sp. **Cerne**, Lavras, v. 18, n. 2, p. 175–184, 2012.

OLIVEIRA, L. T. de et al. Influência da idade na contagem de árvores de *Eucalyptus* sp. com dados de LiDAR. **Cerne**, Lavras, v. 20, n. 4, p. 557–565, 2014.

OTA, T. et al. Aboveground biomass estimation using structure from motion approach with aerial photographs in a seasonal tropical forest. **Forests**, v. 6, n. 11, p. 3882–3898, 2015.

OTA, T. et al. Forest structure estimation from a UAV-Based photogrammetric point cloud in managed temperate coniferous forests. **Forests**, v. 8, n. 9, p. 4–13, 2017.

OZDEMIR, I.; KARNIELI, A. Predicting forest structural parameters using the image texture derived from worldview-2 multispectral imagery in a dryland forest, Israel. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, n. 5, p. 701–710, 2011.

PÁDUA, L. et al. UAS, sensors, and data processing in agroforestry: a review towards practical applications. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2349–2391, 2017.

PAJARES, G. Overview and current status of remote sensing applications based on Unmanned Aerial Vehicles (UAVs). **Photogrammetric Engineering & Remote Sensing**, v. 81, n. 4, p. 281–330, 2015.

PANAGIOTIDIS, D. et al. Determining tree height and crown diameter from high-resolution UAV imagery. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2392–2410, 2016.

PANDA, S. S. et al. Remote Sensing Systems—Platforms and Sensors: Aerial, Satellite, UAV, Optical, Radar, and LiDAR. In: THENKABAIL, P. S. (Ed.). **Remotely Sensed Data Characterization, Classification, and Accuracies**. Boca Raton, FL: CRC Press, 2015. p. 3–57.

PANEQUE-GÁLVEZ, J. et al. Small drones for community-based forest monitoring: An assessment of their feasibility and potential in tropical areas. **Forests**, v. 5, n. 6, p. 1481–1507, 2014.

PÉLLICO NETTO, S.; BRENA, D. A. **Inventário Florestal**. 1. ed. Curitiba: os autores, 1997.

PEÑA, J. M. et al. Estimating tree height and biomass of a poplar plantation with image-based UAV technology. **AIMS Agriculture and Food**, v. 3, n. 3, p. 313–323, 2018.

PIX4D. **Designing the Image Acquisition Plan**. 2018b. Disponível em: <<https://support.pix4d.com/hc/en-us/articles/202557459>>. Acesso em: 9 maio. 2018.

PIX4D. **Pix4D Desktop technical release notes**. 2018a. Disponível em: <<https://support.pix4d.com/hc/en-us/articles/115005738363-Pix4D-Desktop-technical-release-notes>>. Acesso em: 9 maio. 2018.

PRODAN, M. **Forest biometrics**. Oxford: Pergamon Press, 1968.

PULITI, S. et al. Inventory of small forest areas using an Unmanned Aerial System. **Remote Sensing**, v. 7, n. 8, p. 9632–9654, 2015.

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing. Vienna, 2016. Disponível em: <<https://www.r-project.org/>>.

RICHARDS, J. A. **Remote Sensing with Imaging Radar**. 1. ed. Heidelberg: Springer, 2009.

ROBERTS, S. D. et al. Estimating individual tree leaf area in *Loblolly pine* plantations using LiDAR-derived measurements of height and crown dimensions. **Forest Ecology and Management**, v. 213, n. 1–3, p. 54–70, 2005.

ROBINSON, C. et al. Impacts of spatial variability on aboveground biomass estimation from L-band radar in a temperate forest. **Remote Sensing**, v. 5, n. 3, p. 1001–1023, 2013.

ROCK, B. N. et al. Remote Detection of Forest Damage. **BioScience**, v. 36, n. 7, p. 439–445, 1986.

RODRIGUES, J. et al. 3D Modeling of the Milreu Roman Heritage with UAVs. In: Conference on Universal Access in Human-Computer Interaction. **Proceedings...** Cham: Springer, 2016. Disponível em: <http://dx.doi.org/10.1007/978-3-319-40244-4_32>. Acesso em: 9 maio. 2018.

RODRIGUES, J. et al. Desenvolvimento de *Eucalyptus Urograndis* no município de Corumbá-GO. **Ensaio e Ciência: Ciências Biológicas, Agrárias e da Saúde**, v. 17, n. 2, p. 9–27, 2013.

RUZA, M. S. et al. Inventário de Sobrevivência de povoamento de *Eucalyptus* com uso de Redes Neurais Artificiais em Fotografias obtidas por VANTs. **Advances in Forestry Science**, v. 4, n. 4, p. 83–88, 2017.

SAARINEN, N. et al. Assessing Biodiversity in Boreal Forests with UAV-Based Photogrammetric Point Clouds and Hyperspectral Imaging. **Remote Sensing**, v. 10, n. 338, p. 1–22, 2018.

SALAMÍ, E.; BARRADO, C.; PASTOR, E. UAV flight experiments applied to the remote sensing of vegetated areas. **Remote Sensing**, v. 6, n. 11, p. 11051–11081, 2014.

SANKEY, T. et al. UAV lidar and hyperspectral fusion for forest monitoring in the southwestern USA. **Remote Sensing of Environment**, v. 195, p. 30–43, 2017.

SANQUETTA, C. R. et al. **Inventários Florestais: planejamento e execução**. 3. ed. Curitiba: Multi-Graphic Gráfica e editora, 2014.

SANQUETTA, C. R. et al. Selection criteria for linear regression models to estimate individual tree biomasses in the Atlantic Rain Forest, Brazil. **Carbon Balance and Management**, v. 13, n. 1, p. 1-15, 2018.

SANTAMARINA-CAMPOS et al. Usability and Experience of the Creative Industries Through Heuristic Evaluation of Flight Software for Mapping and Photogrammetry with Drones. In: SANTAMARINA-CAMPOS, V.; SEGARRA-OÑA, M. (Eds.). **Drones and the Creative Industry**. Cham: Springer International Publishing, 2018. p. 99–114.

SCHOWENGERDT, R. A. **Remote Sensing: Models and Methods for Image Processing**. 3. ed. Burlington: Elsevier Inc., 2007.

SCOLFORO, J. R. S.; MELLO, J. M. de. **Inventário Florestal**. Lavras: Gráfica Universitária UFLA, 2006.

SENSEFLY LTD. **Extended User Manual: eBee and eBee Ag**. Cheseaux-Lausanne, 2014a.

SENSEFLY LTD. **The drone for precision agriculture**. Cheseaux-Lausanne, 2014b.

SENSEFLY LTD. **User Manual multiSPEC 4C**. Switzerland: 2014c.

SHAHBAZI, M.; THÉAU, J.; MÉNARD, P. Recent applications of unmanned aerial imagery in natural resource management. **GIScience and Remote Sensing**, v. 51, n. 4, p. 339–365, 2014.

SHAO, Z. et al. A multi-view dense point cloud generation algorithm based on low-altitude remote sensing images. **Remote Sensing**, v. 8, n. 5, 2016.

SHEN, Y.-Y. et al. Toward an architecture for subalpine forest health monitoring using commercial off-the-shelf Unmanned Aircraft Systems and sensors. In: 17th AIAA Aviation Technology, Integration, and Operations Conference. **Proceedings...** Colorado, 2017. p. 1–15.

SHINZATO, E. T. et al. Integrating area-based and individual tree detection approaches for estimating tree volume in plantation inventory using aerial image and airborne laser scanning data. **iForest**, v. 10, n. 1, p. 296–302, 2017.

SILVA, C. A. et al. Effect of LiDAR density points on the prediction of height in *Pinus taeda* L. plantations. **Scientia Forestalis**, v. 45, n. 115, p. 481–492, 2017b.

SILVA, C. A. et al. **rLiDAR: LiDAR Data Processing and Visualization**. R package version 0.1.1, 2017a. Disponível em: <<https://cran.r-project.org/package=rLiDAR>>. Acesso em: 20 jun. 2018.

SMITH, M. W.; CARRIVICK, J. L.; QUINCEY, D. J. Structure from motion photogrammetry in physical geography. **Progress in Physical Geography**, v. 40, n. 2, p. 247–275, 2015.

SOARES, C. P. B.; NETO, F. DE P.; SOUZA, A. L. DE. **Dendrometria e Inventário Florestal**. 2. ed. Viçosa: UFV, 2011.

SONA, G. et al. Experimental analysis of different software packages for orientation and digital surface modelling from UAV images. **Earth Science Informatics**, v. 7, n. 2, p. 97–107, 2014.

SOTHE, C. et al. Evaluating Sentinel-2 and Landsat-8 data to map sucessional forest stages in a subtropical forest in Southern Brazil. **Remote Sensing**, v. 9, n. 8, 2017.

SOUZA, J. T. DE; FIORENTIN, L. D. Crescimento de variáveis dendrométricas de *Pinus* spp. na região de Nova Araçá, RS. **Unoesc & Ciência**, Ed. Especial, p. 23–28, 2015.

STANTON, C. et al. Unmanned aircraft system-derived crop height and normalized difference vegetation index metrics for sorghum yield and aphid stress assessment. **Journal of Applied Remote Sensing**, v. 11, n. 2, p. 026035, 2017.

STEREŃCZAK, K.; BĘDKOWSKI, K.; WEINACKER, H. Accuracy of crown segmentation and estimation of selected trees and forest stand parameters in order to resolution of used DSM and NDSM models generated from dense small footprint LIDAR data. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, p. 27–32, 2008.

SUROVÝ, P.; YOSHIMOTO, A.; PANAGIOTIDIS, D. Accuracy of reconstruction of the tree stem surface using terrestrial close-range photogrammetry. **Remote Sensing**, v. 8, n. 2, p. 1–13, 2016.

SZELISKI, R. **Computer Vision**. London: Springer London, 2011.

TANG, L.; SHAO, G. Drone remote sensing for forestry research and practices. **Journal of Forestry Research**, v. 26, n. 4, p. 791–797, 2015.

TANHUANPÄÄ, T. et al. Evaluating the performance of high-altitude aerial image-based digital surface models in detecting individual tree crowns in mature boreal forests. **Forests**, v. 7, n. 7, 2016.

THIEL, C.; SCHMULLIUS, C. Comparison of UAV photograph-based and airborne lidar-based point clouds over forest from a forestry application perspective. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2411–2426, 2017.

TOMAŠTÍK, J. et al. Accuracy of photogrammetric UAV-based point clouds under conditions of partially-open forest canopy. **Forests**, v. 8, n. 5, 2017.

TORRESAN, C. et al. Forestry applications of UAVs in Europe: a review. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2427–2447, 2017.

TORRES-SÁNCHEZ, J. et al. Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. **Precision Agriculture**, v. 19, p. 115–133, 2018.

TOTH, C.; JÓZKÓW, G. Remote sensing platforms and sensors: a survey. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 22–36, 2016.

TRIMBLE GERMANY GMBH. **eCognition® Developer**, versão 8.7, 2011. München.

ULLMAN, S. The interpretation of structure from motion. **Proceedings of the Royal Society of London**, v. 203, n. 1153, p. 405–426, 1979.

VAN LEEUWEN, M.; NIEUWENHUIS, M. Retrieval of forest structural parameters using LiDAR remote sensing. **European Journal of Forest Research**, v. 129, n. 4, p. 749–770, 2010.

VASTERLING, M.; MEYER, U. Challenges and Opportunities for UAV-Borne Thermal Imaging. In: KUENZER, C.; DECH, S. (Eds.). **Thermal Infrared Remote Sensing: Sensors, Methods, Applications**. Dordrecht: Springer, 2013. p. 69–92.

VAUHKONEN, J. et al. Comparative testing of single-tree detection algorithms under different types of forest. **Forestry**, v. 85, n. 1, p. 27–40, 2012.

VAUHKONEN, J. et al. Introduction to forestry applications of airborne laser scanning. In: MALTAMO, M.; NÆSSET, E.; VAUHKONEN, J. (Eds.). **Forestry Applications of Airborne Laser Scanning**. Dordrecht: Springer, 2014. p. 1–16.

VERHOEVEN, G. Taking computer vision aloft – archaeological three-dimensional reconstructions from aerial photographs with photoscan. **Archaeological Prospection**, v. 62, p. 61–62, 2011.

VIEIRA, M. A. et al. Object Based Image Analysis and Data Mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas. **Remote Sensing of Environment**, v. 123, p. 553–562, 2012.

WALLACE, L. et al. Assessment of forest structure using two UAV techniques: a comparison of airborne laser scanning and structure from motion (SfM) point clouds. **Forests**, v. 7, n. 3, p. 1–16, 2016.

WATTS, A. C.; AMBROSIA, V. G.; HINKLEY, E. A. Unmanned aircraft systems in remote sensing and scientific research: classification and considerations of use. **Remote Sensing**, v. 4, n. 6, p. 1671–1692, 2012.

WEST, P. W. **Tree and Forest Measurement**. New York: Springer, 2015.

WHITE, J. C. et al. Remote sensing technologies for enhancing forest inventories: a review. **Canadian Journal of Remote Sensing**, v. 42, n. 5, p. 619–641, 2016.

WHITEHEAD, K. et al. Remote sensing of the environment with small unmanned aircraft systems (UASs), part 2: scientific and commercial applications. **Journal of Unmanned Vehicle Systems**, v. 2, n. 3, p. 86–102, 2014.

WHITEHEAD, K.; HUGENHOLTZ, C. H. Remote sensing of the environment with small unmanned aircraft systems (UASs), part 1: a review of progress and challenges. **Journal of Unmanned Vehicle Systems**, v. 2, n. 3, p. 86–102, 2014.

WIJAYA, A. et al. Improved strategy for estimating stem volume and forest biomass using moderate resolution remote sensing data and GIS. **Journal of Forestry Research**, v. 21, n. 1, p. 1–12, 2010.

WOLF, P. R.; DEWITT, B. A.; WILKINSON, B. E. **Elements of photogrammetry with application in GIS**. New York: McGraw-Hill Education, 2014.

WULDER, M. A. et al. Lidar sampling for large-area forest characterization: a review. **Remote Sensing of Environment**, v. 121, p. 196–209, 2012.

XIE, Y.; SHA, Z.; YU, M. Remote sensing imagery in vegetation mapping: a review. **Journal of Plant Ecology**, v. 1, n. 1, p. 9–23, 2008.

YANG, B.; CHEN, C. Automatic registration of UAV-borne sequent images and LiDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 101, p. 262–274, 2015.

YU, X. et al. Comparison of area-based and individual tree-based methods for predicting plot-level forest attributes. **Remote Sensing**, v. 2, n. 6, p. 1481–1495, 2010.

ZAHAWI, R. A. et al. Using lightweight unmanned aerial vehicles to monitor tropical forest recovery. **Biological Conservation**, v. 186, p. 287–295, 2015.

ZANDONÁ, D. F.; LINGNAU, C.; NAKAJIMA, N. Y. Varredura a Laser aerotransportado para estimativa de variáveis dendrométricas. **Scientia Forestalis**, Piracicaba, v. 36, n. 80, p. 295–306, 2008.

ZARCO-TEJADA, P. J. et al. Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. **European Journal of Agronomy**, v. 55, p. 89–99, 2014.

ZARCO-TEJADA, P. J.; GONZÁLEZ-DUGO, V.; BERNI, J. A. J. Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. **Remote Sensing of Environment**, v. 117, p. 322–337, 2012.

ZHANG, J. et al. Seeing the forest from drones: Testing the potential of lightweight drones as a tool for long-term forest monitoring. **Biological Conservation**, v. 198, p. 60–69, 2016.

ZHANG, K. et al. A progressive morphological filter for removing nonground measurements from airborne LIDAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 4, p. 872–882, 2003.

ZHANG, Y.; XIONG, J.; HAO, L. Photogrammetric processing of low-altitude images acquired by unpiloted aerial vehicles. **Photogrammetric Record**, v. 26, n. 134, p. 190–211, 2011.

ZVOLEFF, A. **Package “glcm”**R package version 1.6.1, 2016. Disponível em: <<http://www.azvoleff.com/glcm>>. Acesso em: 15 out. 2018.

APÊNDICE 1 – CORRELAÇÕES ENTRE VARIÁVEIS

Correlação de Pearson entre dap, altura e volume e demais variáveis – talhão

***Eucalyptus* – câmera NIR**

Variável	dap	h	vol	Variável	dap	h	vol
Area	0,37	0,07	0,33	MDS_2m_sum	-0,17	0,13	-0,15
CHM_sum	0,51	0,39	0,54	MDS_2m_med	-0,29	0,09	-0,25
CHM_med	0,39	0,62	0,49	MDS_2m_stdv	0,03	0,04	0,02
CHM_stdv	0,26	-0,14	0,23	MDS_2m_max	-0,13	0,13	-0,11
CHM_max	0,45	0,51	0,53	Red_var_sum	0,49	0,22	0,44
MDS_sum	0,36	0,08	0,33	Red_var_med	0,37	0,21	0,32
MDS_med	-0,12	0,15	-0,09	Red_var_stdv	0,04	0,20	0,07
MDS_stdv	0,26	-0,17	0,21	Red_hom_sum	0,49	0,13	0,45
MDS_max	-0,10	0,13	-0,07	Red_hom_med	0,40	0,13	0,36
Red_sum	0,54	0,25	0,49	Red_hom_stdv	0,24	0,18	0,24
Red_med	0,40	0,27	0,36	Red_con_sum	-0,19	-0,02	-0,16
Red_stdv	-0,26	0,00	-0,21	Red_con_med	-0,27	-0,04	-0,23
Gre_sum	0,54	0,25	0,49	Red_con_stdv	-0,01	0,07	0,00
Gre_med	0,40	0,27	0,36	Red_dis_sum	-0,21	-0,04	-0,19
Gre_stdv	-0,27	0,00	-0,22	Red_dis_med	-0,36	-0,08	-0,32
NIR_sum	0,51	0,25	0,47	Red_dis_stdv	0,07	0,13	0,08
NIR_med	0,34	0,31	0,31	Red_ent_sum	0,23	0,06	0,22
NIR_stdv	-0,24	-0,02	-0,20	Red_ent_med	-0,25	0,00	-0,22
Intens_sum	0,54	0,25	0,49	Red_ent_stdv	0,25	0,02	0,22
Intens_med	0,40	0,27	0,36	Red_2m_sum	0,41	0,03	0,36
Intens_stdv	-0,27	0,00	-0,22	Red_2m_med	0,25	-0,01	0,21
CHM_var_sum	0,50	0,51	0,56	Red_2m_stdv	0,23	0,01	0,20
CHM_var_med	0,37	0,61	0,47	gre_var_sum	0,49	0,21	0,43
CHM_var_stdv	0,33	-0,07	0,30	gre_var_med	0,36	0,20	0,32
CHM_var_max	0,44	0,56	0,53	gre_var_stdv	0,06	0,21	0,09
CHM_hom_sum	-0,02	0,14	-0,02	gre_hom_sum	0,48	0,13	0,44
CHM_hom_med	-0,28	0,09	-0,27	gre_hom_med	0,39	0,12	0,36
CHM_hom_stdv	0,21	-0,06	0,19	gre_hom_stdv	0,26	0,18	0,26
CHM_hom_max	-0,19	0,09	-0,18	gre_con_sum	-0,20	-0,01	-0,17
CHM_con_sum	0,18	-0,12	0,14	gre_con_med	-0,27	-0,03	-0,24
CHM_con_med	0,17	-0,12	0,13	gre_con_stdv	-0,01	0,08	0,01
CHM_con_stdv	0,18	-0,10	0,14	gre_dis_sum	-0,21	-0,04	-0,19
CHM_con_max	0,20	-0,10	0,16	gre_dis_med	-0,36	-0,07	-0,32
CHM_dis_sum	0,31	-0,14	0,27	gre_dis_stdv	0,07	0,14	0,09
CHM_dis_med	0,28	-0,15	0,23	gre_ent_sum	0,24	0,06	0,22
CHM_dis_stdv	0,21	-0,12	0,17	gre_ent_med	-0,26	-0,01	-0,23
CHM_dis_max	0,25	-0,13	0,21	gre_ent_stdv	0,25	0,03	0,22
CHM_ent_sum	0,36	-0,02	0,34	gre_2m_sum	0,41	0,04	0,36
CHM_ent_med	0,28	-0,04	0,27	gre_2m_med	0,25	0,00	0,21
CHM_ent_stdv	-0,04	0,00	-0,04	gre_2m_stdv	0,23	0,00	0,19
CHM_ent_max	0,27	-0,03	0,26	NIR_var_sum	0,48	0,26	0,43
CHM_2m_sum	-0,16	0,05	-0,16	NIR_var_med	0,30	0,26	0,27
CHM_2m_med	-0,26	0,03	-0,25	NIR_var_stdv	-0,01	0,14	0,02
CHM_2m_stdv	-0,16	0,02	-0,16	NIR_hom_sum	0,45	0,15	0,42
CHM_2m_max	-0,20	0,04	-0,20	NIR_hom_med	0,34	0,15	0,33
MDS_var_sum	0,00	0,16	0,02	NIR_hom_stdv	0,29	0,17	0,28
MDS_var_med	-0,11	0,13	-0,09	NIR_con_sum	-0,14	-0,04	-0,14
MDS_var_stdv	0,26	-0,14	0,22	NIR_con_med	-0,23	-0,07	-0,22
MDS_var_max	-0,10	0,11	-0,08	NIR_con_stdv	0,05	0,04	0,04
MDS_hom_sum	0,04	0,20	0,06	NIR_dis_sum	-0,14	-0,07	-0,14
MDS_hom_med	-0,28	0,17	-0,24	NIR_dis_med	-0,32	-0,11	-0,30
MDS_hom_stdv	0,29	-0,11	0,24	NIR_dis_stdv	0,15	0,10	0,15
MDS_hom_max	-0,07	0,19	-0,04	NIR_ent_sum	0,30	0,06	0,28
MDS_con_sum	0,16	-0,11	0,11	NIR_ent_med	-0,15	0,00	-0,14
MDS_con_med	0,15	-0,11	0,11	NIR_ent_stdv	0,17	0,01	0,15
MDS_con_stdv	0,17	-0,08	0,13	NIR_2m_sum	0,37	0,04	0,34
MDS_con_max	0,18	-0,09	0,15	NIR_2m_med	0,15	0,00	0,13
MDS_dis_sum	0,27	-0,18	0,21	NIR_2m_stdv	0,15	0,01	0,13
MDS_dis_med	0,25	-0,18	0,19				
MDS_dis_stdv	0,22	-0,11	0,17				
MDS_dis_max	0,24	-0,13	0,19				
MDS_ent_sum	0,34	-0,11	0,30				
MDS_ent_med	0,30	-0,11	0,27				
MDS_ent_stdv	0,17	-0,02	0,14				
MDS_ent_max	0,32	-0,09	0,28				

Correlação de Pearson entre dap, altura e volume e demais variáveis – talhão

Eucalyptus – câmara Multi

Variável	dap	h	vol	Variável	dap	h	vol	Variável	dap	h	vol
Area	0,32	0,14	0,32	MDS_ent_stdv	0,21	0,02	0,20	NIR_dis_sum	-0,22	-0,09	-0,22
CHM_sum	0,45	0,43	0,49	MDS_ent_max	0,26	-0,10	0,22	NIR_dis_med	-0,35	-0,15	-0,36
CHM_med	0,34	0,61	0,44	MDS_2m_sum	-0,11	0,20	-0,08	NIR_dis_stdv	-0,05	-0,10	-0,08
CHM_stdv	0,23	-0,12	0,21	MDS_2m_med	-0,24	0,15	-0,21	NIR_ent_sum	0,15	0,08	0,13
CHM_max	0,42	0,55	0,51	MDS_2m_stdv	0,18	0,07	0,18	NIR_ent_med	-0,29	-0,08	-0,29
MDS_sum	0,32	0,15	0,31	MDS_2m_max	-0,06	0,28	0,00	NIR_ent_stdv	0,23	0,06	0,23
MDS_med	-0,15	0,14	-0,12	Gre_var_sum	0,32	-0,11	0,25	NIR_2m_sum	0,40	0,13	0,40
MDS_stdv	0,12	-0,22	0,08	Gre_var_med	0,22	-0,17	0,14	NIR_2m_med	0,27	0,07	0,28
MDS_max	-0,14	0,10	-0,11	Gre_var_stdv	0,13	-0,01	0,10	NIR_2m_stdv	0,21	0,04	0,21
Gre_sum	0,38	-0,02	0,31	Gre_hom_sum	0,38	0,23	0,39				
Gre_med	0,24	-0,13	0,16	Gre_hom_med	0,24	0,22	0,26				
Gre_stdv	-0,09	-0,02	-0,09	Gre_hom_stdv	0,01	-0,11	0,00				
Red_sum	0,23	-0,15	0,18	Gre_con_sum	-0,10	-0,24	-0,12				
Red_med	0,12	-0,24	0,06	Gre_con_med	-0,15	-0,27	-0,17				
Red_stdv	0,10	-0,08	0,10	Gre_con_stdv	-0,03	-0,20	-0,06				
RE_sum	0,31	0,25	0,28	Gre_dis_sum	-0,11	-0,20	-0,13				
RE_med	0,11	0,20	0,08	Gre_dis_med	-0,22	-0,25	-0,25				
RE_stdv	-0,32	-0,02	-0,31	Gre_dis_stdv	-0,02	-0,18	-0,04				
NIR_sum	0,31	0,28	0,28	Gre_ent_sum	-0,02	-0,04	-0,03				
NIR_med	0,10	0,22	0,07	Gre_ent_med	-0,21	-0,13	-0,23				
NIR_stdv	-0,30	-0,04	-0,29	Gre_ent_stdv	0,06	-0,03	0,07				
NDVI_sum	0,32	0,25	0,32	Gre_2m_sum	0,30	0,13	0,30				
NDVI_med	0,00	0,34	0,03	Gre_2m_med	0,21	0,10	0,22				
NDVI_stdv	0,00	-0,22	-0,01	Gre_2m_stdv	0,13	0,03	0,14				
NDRE_sum	0,18	0,15	0,18	Red_var_sum	0,14	-0,18	0,10				
NDRE_med	-0,06	0,07	-0,06	Red_var_med	0,09	-0,21	0,05				
NDRE_stdv	-0,16	-0,10	-0,14	Red_var_stdv	0,13	-0,10	0,11				
CHM_var_sum	0,44	0,53	0,51	Red_hom_sum	0,18	0,25	0,20				
CHM_var_med	0,33	0,61	0,42	Red_hom_med	-0,12	0,20	-0,07				
CHM_var_stdv	0,27	-0,07	0,26	Red_hom_stdv	0,14	-0,10	0,10				
CHM_var_max	0,41	0,58	0,51	Red_con_sum	0,08	-0,20	0,05				
CHM_hom_sum	-0,05	0,14	-0,05	Red_con_med	0,07	-0,21	0,04				
CHM_hom_med	-0,26	0,08	-0,25	Red_con_stdv	0,08	-0,15	0,05				
CHM_hom_stdv	0,19	-0,01	0,18	Red_dis_sum	0,13	-0,19	0,09				
CHM_hom_max	-0,18	0,07	-0,18	Red_dis_med	0,11	-0,21	0,06				
CHM_con_sum	0,19	-0,10	0,15	Red_dis_stdv	0,12	-0,15	0,09				
CHM_con_med	0,17	-0,10	0,13	Red_ent_sum	0,17	-0,15	0,13				
CHM_con_stdv	0,19	-0,10	0,15	Red_ent_med	0,13	-0,17	0,08				
CHM_con_max	0,20	-0,10	0,16	Red_ent_stdv	0,13	0,02	0,11				
CHM_dis_sum	0,29	-0,11	0,25	Red_2m_sum	-0,02	0,20	0,03				
CHM_dis_med	0,24	-0,14	0,20	Red_2m_med	-0,14	0,16	-0,09				
CHM_dis_stdv	0,22	-0,11	0,18	Red_2m_stdv	0,10	0,09	0,10				
CHM_dis_max	0,25	-0,12	0,21	RE_var_sum	0,18	0,21	0,15				
CHM_ent_sum	0,33	0,03	0,34	RE_var_med	0,04	0,16	0,01				
CHM_ent_med	0,24	-0,03	0,25	RE_var_stdv	-0,14	0,12	-0,14				
CHM_ent_stdv	-0,06	0,01	-0,07	RE_hom_sum	0,46	0,12	0,45				
CHM_ent_max	0,24	-0,01	0,23	RE_hom_med	0,39	0,08	0,38				
CHM_2m_sum	-0,13	0,04	-0,14	RE_hom_stdv	0,21	0,04	0,20				
CHM_2m_med	-0,22	0,01	-0,22	RE_con_sum	-0,35	-0,15	-0,35				
CHM_2m_stdv	-0,14	0,01	-0,15	RE_con_med	-0,41	-0,18	-0,41				
CHM_2m_max	-0,17	0,03	-0,17	RE_con_stdv	-0,22	-0,12	-0,23				
MDS_var_sum	-0,03	0,15	-0,02	RE_dis_sum	-0,30	-0,10	-0,31				
MDS_var_med	-0,14	0,11	-0,11	RE_dis_med	-0,44	-0,15	-0,43				
MDS_var_stdv	0,16	-0,19	0,13	RE_dis_stdv	-0,10	-0,10	-0,11				
MDS_var_max	-0,12	0,08	-0,11	RE_ent_sum	0,17	0,11	0,16				
MDS_hom_sum	0,11	0,26	0,14	RE_ent_med	-0,30	-0,05	-0,30				
MDS_hom_med	-0,22	0,24	-0,16	RE_ent_stdv	0,24	0,03	0,24				
MDS_hom_stdv	0,25	-0,10	0,22	RE_2m_sum	0,41	0,11	0,40				
MDS_hom_max	-0,05	0,30	0,02	RE_2m_med	0,28	0,03	0,28				
MDS_con_sum	0,08	-0,18	0,05	RE_2m_stdv	0,21	0,01	0,21				
MDS_con_med	0,08	-0,17	0,05	NIR_var_sum	0,18	0,23	0,15				
MDS_con_stdv	0,10	-0,16	0,07	NIR_var_med	0,03	0,18	0,00				
MDS_con_max	0,12	-0,15	0,09	NIR_var_stdv	-0,15	0,09	-0,16				
MDS_dis_sum	0,18	-0,23	0,13	NIR_hom_sum	0,39	0,13	0,39				
MDS_dis_med	0,17	-0,24	0,11	NIR_hom_med	0,30	0,09	0,30				
MDS_dis_stdv	0,16	-0,18	0,12	NIR_hom_stdv	0,19	0,02	0,18				
MDS_dis_max	0,18	-0,19	0,14	NIR_con_sum	-0,27	-0,15	-0,28				
MDS_ent_sum	0,28	-0,15	0,24	NIR_con_med	-0,33	-0,18	-0,34				
MDS_ent_med	0,25	-0,18	0,20	NIR_con_stdv	-0,16	-0,13	-0,18				

Correlação de Pearson entre dap, altura e volume e demais variáveis – talhão

Pinus 1 – câmera RGB

Variável	dap	h	vol	Variável	dap	h	vol
Area	0,30	0,14	0,27	Red_var_sum	0,30	0,33	0,35
CHM_sum	0,42	0,35	0,45	Red_var_med	0,18	0,29	0,25
CHM_med	0,36	0,47	0,44	Red_var_stdv	0,11	0,15	0,13
CHM_stdv	0,08	0,00	0,08	Red_hom_sum	0,18	0,01	0,14
CHM_max	0,36	0,43	0,43	Red_hom_med	0,04	-0,07	0,01
MDS_sum	0,30	0,15	0,27	Red_hom_stdv	0,03	-0,07	0,00
MDS_med	-0,07	-0,06	-0,09	Red_con_sum	0,03	0,00	0,01
MDS_stdv	0,05	-0,05	0,04	Red_con_med	-0,08	-0,05	-0,09
MDS_max	-0,06	-0,07	-0,08	Red_con_stdv	-0,03	-0,03	-0,03
Red_sum	0,33	0,33	0,37	Red_dis_sum	0,12	0,07	0,10
Red_med	0,18	0,31	0,25	Red_dis_med	-0,08	-0,02	-0,07
Red_stdv	-0,03	-0,02	-0,04	Red_dis_stdv	-0,01	-0,04	-0,02
Gre_sum	0,33	0,33	0,37	Red_ent_sum	0,30	0,16	0,27
Gre_med	0,18	0,31	0,25	Red_ent_med	0,01	0,12	0,05
Gre_stdv	-0,06	-0,04	-0,07	Red_ent_stdv	-0,01	-0,11	-0,05
Blue_sum	0,34	0,32	0,37	Red_2m_sum	0,24	0,05	0,19
Blue_med	0,18	0,30	0,26	Red_2m_med	-0,01	-0,13	-0,05
Blue_stdv	-0,05	-0,05	-0,07	Red_2m_stdv	-0,02	-0,12	-0,05
Intens_sum	0,33	0,33	0,37	Gre_var_sum	0,30	0,33	0,35
Intens_med	0,18	0,31	0,25	Gre_var_med	0,17	0,30	0,25
Intens_stdv	-0,05	-0,04	-0,07	Gre_var_stdv	0,07	0,13	0,10
CHM_var_sum	0,44	0,42	0,49	Gre_hom_sum	0,17	0,02	0,14
CHM_var_med	0,36	0,46	0,45	Gre_hom_med	0,04	-0,05	0,02
CHM_var_stdv	0,16	0,10	0,18	Gre_hom_stdv	0,03	-0,05	0,01
CHM_var_max	0,35	0,43	0,43	Gre_con_sum	0,01	-0,02	-0,01
CHM_hom_sum	0,24	0,12	0,21	Gre_con_med	-0,11	-0,07	-0,11
CHM_hom_med	-0,06	-0,02	-0,06	Gre_con_stdv	-0,04	-0,04	-0,05
CHM_hom_stdv	0,01	-0,06	-0,01	Gre_dis_sum	0,10	0,05	0,08
CHM_hom_max	-0,01	-0,01	-0,02	Gre_dis_med	-0,10	-0,04	-0,10
CHM_con_sum	0,06	-0,05	0,04	Gre_dis_stdv	-0,02	-0,04	-0,03
CHM_con_med	0,01	-0,07	0,00	Gre_ent_sum	0,30	0,16	0,27
CHM_con_stdv	0,01	-0,09	-0,02	Gre_ent_med	-0,01	0,10	0,03
CHM_con_max	0,00	-0,10	-0,02	Gre_ent_stdv	0,01	-0,08	-0,02
CHM_dis_sum	0,16	0,04	0,14	Gre_2m_sum	0,23	0,05	0,19
CHM_dis_med	0,05	-0,02	0,04	Gre_2m_med	0,00	-0,10	-0,03
CHM_dis_stdv	0,01	-0,10	-0,02	Gre_2m_stdv	-0,01	-0,10	-0,04
CHM_dis_max	0,02	-0,09	0,00	Blue_var_sum	0,31	0,32	0,35
CHM_ent_sum	0,24	0,10	0,22	Blue_var_med	0,18	0,29	0,25
CHM_ent_med	0,08	0,02	0,08	Blue_var_stdv	0,07	0,10	0,08
CHM_ent_stdv	-0,04	-0,09	-0,06	Blue_hom_sum	0,19	0,03	0,16
CHM_ent_max	0,06	-0,05	0,04	Blue_hom_med	0,05	-0,05	0,03
CHM_2m_sum	0,09	0,04	0,06	Blue_hom_stdv	0,05	-0,06	0,01
CHM_2m_med	-0,09	-0,04	-0,09	Blue_con_sum	0,02	-0,02	0,00
CHM_2m_stdv	-0,07	-0,07	-0,08	Blue_con_med	-0,08	-0,07	-0,10
CHM_2m_max	-0,03	-0,02	-0,04	Blue_con_stdv	-0,03	-0,05	-0,04
MDS_var_sum	0,03	-0,02	0,00	Blue_dis_sum	0,11	0,05	0,09
MDS_var_med	-0,05	-0,08	-0,08	Blue_dis_med	-0,08	-0,04	-0,08
MDS_var_stdv	0,02	-0,07	0,00	Blue_dis_stdv	0,00	-0,05	-0,02
MDS_var_max	-0,05	-0,08	-0,08	Blue_ent_sum	0,29	0,16	0,27
MDS_hom_sum	0,25	0,15	0,23	Blue_ent_med	-0,03	0,11	0,01
MDS_hom_med	-0,07	-0,02	-0,07	Blue_ent_stdv	0,03	-0,10	-0,01
MDS_hom_stdv	0,03	-0,04	0,01	Blue_2m_sum	0,24	0,04	0,19
MDS_hom_max	-0,02	-0,04	-0,04	Blue_2m_med	0,02	-0,12	-0,02
MDS_con_sum	0,09	0,01	0,08	Blue_2m_stdv	0,02	-0,11	-0,02
MDS_con_med	0,06	-0,03	0,05				
MDS_con_stdv	0,06	-0,03	0,04				
MDS_con_max	0,06	-0,03	0,05				
MDS_dis_sum	0,18	0,08	0,17				
MDS_dis_med	0,07	0,00	0,07				
MDS_dis_stdv	0,05	-0,05	0,03				
MDS_dis_max	0,08	-0,03	0,06				
MDS_ent_sum	0,23	0,12	0,22				
MDS_ent_med	0,08	0,02	0,08				
MDS_ent_stdv	-0,03	-0,07	-0,05				
MDS_ent_max	0,08	-0,03	0,06				
MDS_2m_sum	0,10	0,07	0,09				
MDS_2m_med	-0,08	-0,03	-0,08				
MDS_2m_stdv	-0,05	-0,05	-0,06				
MDS_2m_max	-0,04	-0,03	-0,05				

Correlação de Pearson entre dap, altura e volume e demais variáveis – talhão

Pinus 1 – câmera NIR

Variável	dap	h	vol	Variável	dap	h	vol
Area	0,30	0,14	0,27	Red_var_sum	0,41	0,40	0,47
CHM_sum	0,43	0,37	0,46	Red_var_med	0,35	0,39	0,42
CHM_med	0,37	0,51	0,47	Red_var_stdv	0,24	0,30	0,30
CHM_stdv	0,06	-0,03	0,05	Red_hom_sum	0,23	0,07	0,20
CHM_max	0,36	0,48	0,46	Red_hom_med	0,09	0,00	0,08
MDS_sum	0,30	0,14	0,26	Red_hom_stdv	0,01	0,00	0,01
MDS_med	-0,06	-0,05	-0,08	Red_con_sum	-0,06	-0,03	-0,07
MDS_stdv	0,11	0,01	0,11	Red_con_med	-0,17	-0,09	-0,17
MDS_max	-0,06	-0,06	-0,08	Red_con_stdv	-0,13	-0,09	-0,14
Red_sum	0,43	0,39	0,48	Red_dis_sum	0,05	0,03	0,03
Red_med	0,35	0,40	0,42	Red_dis_med	-0,16	-0,07	-0,16
Red_stdv	-0,07	0,01	-0,05	Red_dis_stdv	-0,11	-0,06	-0,12
Gre_sum	0,43	0,39	0,48	Red_ent_sum	0,30	0,14	0,26
Gre_med	0,35	0,39	0,42	Red_ent_med	-0,04	0,00	-0,04
Gre_stdv	-0,08	0,00	-0,07	Red_ent_stdv	0,00	-0,03	-0,01
NIR_sum	0,43	0,35	0,46	Red_2m_sum	0,25	0,10	0,22
NIR_med	0,33	0,39	0,41	Red_2m_med	0,02	-0,01	0,02
NIR_stdv	0,08	0,15	0,11	Red_2m_stdv	-0,02	-0,04	-0,03
Intens_sum	0,43	0,39	0,48	Gre_var_sum	0,41	0,39	0,47
Intens_med	0,35	0,39	0,42	Gre_var_med	0,34	0,39	0,42
Intens_stdv	-0,07	0,02	-0,05	Gre_var_stdv	0,24	0,29	0,30
CHM_var_sum	0,45	0,45	0,51	Gre_hom_sum	0,22	0,06	0,19
CHM_var_med	0,37	0,51	0,47	Gre_hom_med	0,08	-0,01	0,06
CHM_var_stdv	0,16	0,11	0,18	Gre_hom_stdv	-0,02	-0,05	-0,04
CHM_var_max	0,37	0,47	0,46	Gre_con_sum	-0,06	-0,03	-0,08
CHM_hom_sum	0,25	0,12	0,21	Gre_con_med	-0,18	-0,09	-0,18
CHM_hom_med	-0,09	-0,01	-0,08	Gre_con_stdv	-0,12	-0,08	-0,13
CHM_hom_stdv	0,07	-0,01	0,05	Gre_dis_sum	0,05	0,03	0,02
CHM_hom_max	0,01	0,00	-0,01	Gre_dis_med	-0,17	-0,07	-0,16
CHM_con_sum	0,17	0,04	0,16	Gre_dis_stdv	-0,10	-0,07	-0,11
CHM_con_med	0,08	-0,01	0,07	Gre_ent_sum	0,30	0,14	0,26
CHM_con_stdv	0,04	-0,04	0,03	Gre_ent_med	-0,01	0,03	-0,01
CHM_con_max	0,06	-0,04	0,05	Gre_ent_stdv	-0,03	-0,06	-0,04
CHM_dis_sum	0,20	0,06	0,18	Gre_2m_sum	0,21	0,07	0,18
CHM_dis_med	0,09	0,00	0,08	Gre_2m_med	-0,01	-0,04	-0,02
CHM_dis_stdv	0,06	-0,02	0,05	Gre_2m_stdv	-0,05	-0,06	-0,06
CHM_dis_max	0,08	-0,02	0,07	NIR_var_sum	0,41	0,38	0,47
CHM_ent_sum	0,21	0,06	0,19	NIR_var_med	0,32	0,38	0,40
CHM_ent_med	0,08	-0,01	0,07	NIR_var_stdv	0,22	0,26	0,27
CHM_ent_stdv	0,00	-0,04	-0,02	NIR_hom_sum	0,15	-0,01	0,11
CHM_ent_max	0,05	-0,03	0,04	NIR_hom_med	-0,01	-0,11	-0,04
CHM_2m_sum	0,09	0,06	0,07	NIR_hom_stdv	-0,01	-0,01	-0,01
CHM_2m_med	-0,09	-0,01	-0,08	NIR_con_sum	0,07	0,09	0,07
CHM_2m_stdv	-0,02	-0,03	-0,03	NIR_con_med	-0,06	0,03	-0,05
CHM_2m_max	0,00	0,00	-0,01	NIR_con_stdv	-0,07	-0,03	-0,07
MDS_var_sum	0,03	-0,03	0,00	NIR_dis_sum	0,17	0,15	0,17
MDS_var_med	-0,05	-0,06	-0,07	NIR_dis_med	-0,04	0,06	-0,02
MDS_var_stdv	0,04	-0,05	0,01	NIR_dis_stdv	-0,06	-0,02	-0,07
MDS_var_max	-0,05	-0,07	-0,07	NIR_ent_sum	0,30	0,15	0,27
MDS_hom_sum	0,24	0,11	0,20	NIR_ent_med	-0,01	0,07	0,00
MDS_hom_med	-0,12	-0,05	-0,13	NIR_ent_stdv	0,02	-0,06	0,01
MDS_hom_stdv	0,06	0,00	0,06	NIR_2m_sum	0,28	0,10	0,24
MDS_hom_max	-0,02	-0,04	-0,04	NIR_2m_med	0,01	-0,07	0,00
MDS_con_sum	0,20	0,08	0,20	NIR_2m_stdv	0,02	-0,06	0,01
MDS_con_med	0,13	0,04	0,13				
MDS_con_stdv	0,08	0,00	0,08				
MDS_con_max	0,10	0,00	0,09				
MDS_dis_sum	0,21	0,09	0,21				
MDS_dis_med	0,12	0,05	0,13				
MDS_dis_stdv	0,07	0,00	0,07				
MDS_dis_max	0,12	0,03	0,12				
MDS_ent_sum	0,23	0,10	0,22				
MDS_ent_med	0,13	0,05	0,14				
MDS_ent_stdv	-0,02	-0,06	-0,04				
MDS_ent_max	0,11	0,00	0,10				
MDS_2m_sum	0,07	0,04	0,05				
MDS_2m_med	-0,13	-0,05	-0,13				
MDS_2m_stdv	-0,06	-0,07	-0,08				
MDS_2m_max	-0,07	-0,06	-0,08				

Correlação de Pearson entre dap, altura e volume e demais variáveis – talhão

Pinus 1 – câmara Multi

Variável	dap	h	vol	Variável	dap	h	vol	Variável	dap	h	vol
Area	0,30	0,14	0,27	MDS_ent_stdv	0,06	-0,01	0,05	RE_dis_sum	0,08	0,04	0,06
CHM_sum	0,43	0,38	0,46	MDS_ent_max	0,08	-0,02	0,06	RE_dis_med	-0,12	-0,05	-0,12
CHM_med	0,36	0,50	0,46	MDS_2m_sum	0,14	0,10	0,12	RE_dis_stde	-0,12	-0,12	-0,14
CHM_stdv	0,11	0,05	0,12	MDS_2m_med	-0,08	0,01	-0,08	RE_ent_sum	0,26	0,12	0,22
CHM_max	0,37	0,49	0,46	MDS_2m_stdv	0,06	-0,01	0,05	RE_ent_med	-0,08	-0,04	-0,09
MDS_sum	0,30	0,13	0,26	MDS_2m_max	0,04	0,04	0,04	RE_ent_stde	0,02	-0,03	0,00
MDS_med	-0,07	-0,06	-0,09	Gre_var_sum	0,39	0,35	0,44	RE_2m_sum	0,24	0,10	0,22
MDS_stdv	0,06	-0,05	0,04	Gre_var_med	0,31	0,35	0,38	RE_2m_med	0,06	0,02	0,06
MDS_max	-0,07	-0,07	-0,09	Gre_var_stdv	0,20	0,24	0,25	RE_2m_stde	-0,01	-0,04	-0,02
Gre_sum	0,43	0,36	0,47	Gre_hom_sum	0,12	-0,05	0,07				
Gre_med	0,34	0,38	0,41	Gre_hom_med	-0,09	-0,18	-0,12				
Gre_stdv	0,08	0,15	0,11	Gre_hom_stdv	-0,03	-0,08	-0,05				
Red_sum	0,43	0,34	0,46	Gre_con_sum	0,09	0,12	0,10				
Red_med	0,34	0,35	0,40	Gre_con_med	0,01	0,07	0,02				
Red_stdv	0,16	0,19	0,18	Gre_con_stdv	0,00	0,02	0,00				
NIR_sum	0,36	0,26	0,38	Gre_dis_sum	0,19	0,18	0,19				
NIR_med	0,24	0,26	0,30	Gre_dis_med	0,04	0,12	0,06				
NIR_stdv	-0,07	-0,05	-0,08	Gre_dis_stdv	-0,01	0,00	-0,02				
RE_sum	0,39	0,31	0,41	Gre_ent_sum	0,32	0,18	0,29				
RE_med	0,27	0,31	0,34	Gre_ent_med	0,08	0,16	0,11				
RE_stdv	-0,07	-0,03	-0,07	Gre_ent_stdv	-0,08	-0,14	-0,10				
NDVI_sum	0,28	0,12	0,24	Gre_2m_sum	0,17	-0,01	0,12				
NDVI_med	-0,13	-0,12	-0,14	Gre_2m_med	-0,08	-0,17	-0,11				
NDVI_stdv	0,01	-0,04	-0,02	Gre_2m_stdv	-0,08	-0,15	-0,11				
NDRE_sum	0,19	0,02	0,15	Red_var_sum	0,35	0,30	0,39				
NDRE_med	-0,08	-0,16	-0,10	Red_var_med	0,24	0,28	0,31				
NDRE_stdv	-0,19	-0,28	-0,25	Red_var_stdv	0,08	0,10	0,10				
CHM_var_sum	0,45	0,45	0,51	Red_hom_sum	0,25	0,09	0,22				
CHM_var_med	0,36	0,49	0,46	Red_hom_med	0,06	-0,01	0,05				
CHM_var_stdv	0,17	0,13	0,19	Red_hom_stdv	-0,04	-0,07	-0,06				
CHM_var_max	0,36	0,47	0,46	Red_con_sum	-0,03	-0,04	-0,06				
CHM_hom_sum	0,20	0,08	0,17	Red_con_med	-0,15	-0,09	-0,15				
CHM_hom_med	-0,13	-0,09	-0,14	Red_con_stdv	-0,12	-0,11	-0,14				
CHM_hom_stdv	0,07	0,04	0,07	Red_dis_sum	0,08	0,04	0,06				
CHM_hom_max	-0,05	-0,05	-0,07	Red_dis_med	-0,12	-0,05	-0,12				
CHM_con_sum	0,19	0,10	0,20	Red_dis_stdv	-0,12	-0,12	-0,14				
CHM_con_med	0,13	0,07	0,14	Red_ent_sum	0,26	0,20	0,25				
CHM_con_stdv	0,10	0,03	0,10	Red_ent_med	0,12	0,16	0,14				
CHM_con_max	0,11	0,01	0,10	Red_ent_stdv	-0,08	-0,10	-0,09				
CHM_dis_sum	0,24	0,13	0,24	Red_2m_sum	0,05	-0,08	0,01				
CHM_dis_med	0,14	0,09	0,15	Red_2m_med	-0,14	-0,18	-0,15				
CHM_dis_stdv	0,10	0,04	0,09	Red_2m_stdv	-0,10	-0,13	-0,12				
CHM_dis_max	0,13	0,05	0,13	NIR_var_sum	0,31	0,24	0,34				
CHM_ent_sum	0,28	0,15	0,27	NIR_var_med	0,21	0,22	0,26				
CHM_ent_med	0,14	0,09	0,15	NIR_var_stdv	0,05	0,06	0,07				
CHM_ent_stdv	-0,03	-0,03	-0,04	NIR_hom_sum	0,25	0,13	0,23				
CHM_ent_max	0,13	0,06	0,13	NIR_hom_med	0,07	0,05	0,07				
CHM_2m_sum	0,04	0,00	0,01	NIR_hom_stdv	-0,03	-0,06	-0,05				
CHM_2m_med	-0,14	-0,08	-0,15	NIR_con_sum	-0,03	-0,05	-0,05				
CHM_2m_stdv	-0,08	-0,06	-0,10	NIR_con_med	-0,12	-0,09	-0,13				
CHM_2m_max	-0,06	-0,05	-0,08	NIR_con_stdv	-0,09	-0,10	-0,11				
MDS_var_sum	0,02	-0,03	-0,01	NIR_dis_sum	0,07	0,00	0,04				
MDS_var_med	-0,05	-0,07	-0,07	NIR_dis_med	-0,11	-0,08	-0,11				
MDS_var_stdv	0,02	-0,05	0,00	NIR_dis_stdv	-0,10	-0,12	-0,13				
MDS_var_max	-0,05	-0,08	-0,08	NIR_ent_sum	0,26	0,10	0,22				
MDS_hom_sum	0,27	0,13	0,23	NIR_ent_med	-0,09	-0,07	-0,10				
MDS_hom_med	-0,07	-0,01	-0,08	NIR_ent_stdv	0,02	0,00	0,02				
MDS_hom_stdv	0,08	0,01	0,08	NIR_2m_sum	0,27	0,14	0,25				
MDS_hom_max	0,03	0,04	0,03	NIR_2m_med	0,08	0,07	0,09				
MDS_con_sum	0,14	0,03	0,14	NIR_2m_stdv	0,01	0,00	0,01				
MDS_con_med	0,07	0,00	0,08	RE_var_sum	0,35	0,30	0,39				
MDS_con_stdv	0,07	-0,01	0,07	RE_var_med	0,24	0,28	0,31				
MDS_con_max	0,07	-0,03	0,06	RE_var_stde	0,08	0,10	0,10				
MDS_dis_sum	0,14	0,04	0,14	RE_hom_sum	0,25	0,09	0,22				
MDS_dis_med	0,07	0,01	0,08	RE_hom_med	0,06	-0,01	0,05				
MDS_dis_stdv	0,08	0,01	0,08	RE_hom_stde	-0,04	-0,07	-0,06				
MDS_dis_max	0,09	0,00	0,08	RE_con_sum	-0,03	-0,04	-0,06				
MDS_ent_sum	0,15	0,03	0,14	RE_con_med	-0,15	-0,09	-0,15				
MDS_ent_med	0,08	-0,01	0,08	RE_con_stde	-0,12	-0,11	-0,14				

Correlação de Pearson entre dap, altura e volume e demais variáveis – talhão

Pinus 2 – câmera RGB

Variável	dap	h	vol	Variável	dap	h	vol
Area	0,31	0,15	0,29	Red_var_sum	0,53	0,37	0,54
CHM_sum	0,52	0,48	0,54	Red_var_med	0,50	0,38	0,51
CHM_med	0,48	0,61	0,55	Red_var_stdv	0,44	0,37	0,46
CHM_stdv	0,17	0,17	0,21	Red_hom_sum	-0,18	-0,23	-0,17
CHM_max	0,46	0,58	0,53	Red_hom_med	-0,28	-0,28	-0,27
MDS_sum	0,32	0,15	0,29	Red_hom_stdv	-0,15	-0,17	-0,14
MDS_med	0,03	-0,03	0,00	Red_con_sum	0,15	0,17	0,12
MDS_stdv	0,10	0,04	0,13	Red_con_med	0,06	0,13	0,04
MDS_max	0,03	-0,04	0,01	Red_con_stdv	-0,11	-0,06	-0,12
Red_sum	0,60	0,42	0,60	Red_dis_sum	0,29	0,26	0,26
Red_med	0,56	0,43	0,56	Red_dis_med	0,16	0,21	0,14
Red_stdv	0,30	0,34	0,28	Red_dis_stdv	-0,12	-0,09	-0,13
Gre_sum	0,61	0,42	0,61	Red_ent_sum	0,35	0,19	0,32
Gre_med	0,57	0,44	0,58	Red_ent_med	0,22	0,25	0,20
Gre_stdv	0,27	0,32	0,25	Red_ent_stdv	-0,19	-0,23	-0,18
Blue_sum	0,62	0,43	0,61	Red_2m_sum	0,15	-0,01	0,13
Blue_med	0,59	0,46	0,60	Red_2m_med	-0,21	-0,24	-0,19
Blue_stdv	0,23	0,30	0,21	Red_2m_stdv	-0,18	-0,22	-0,17
Intens_sum	0,61	0,42	0,61	Gre_var_sum	0,54	0,38	0,55
Intens_med	0,57	0,44	0,58	Gre_var_med	0,51	0,39	0,52
Intens_stdv	0,28	0,32	0,25	Gre_var_stdv	0,44	0,37	0,46
CHM_var_sum	0,52	0,55	0,57	Gre_hom_sum	-0,16	-0,22	-0,15
CHM_var_med	0,45	0,59	0,52	Gre_hom_med	-0,27	-0,28	-0,25
CHM_var_stdv	0,20	0,20	0,26	Gre_hom_stdv	-0,13	-0,17	-0,13
CHM_var_max	0,43	0,56	0,51	Gre_con_sum	0,13	0,15	0,10
CHM_hom_sum	0,15	0,00	0,10	Gre_con_med	0,04	0,11	0,01
CHM_hom_med	-0,08	-0,13	-0,12	Gre_con_stdv	-0,12	-0,07	-0,13
CHM_hom_stdv	0,01	0,00	0,03	Gre_dis_sum	0,27	0,24	0,24
CHM_hom_max	-0,04	-0,11	-0,07	Gre_dis_med	0,14	0,19	0,11
CHM_con_sum	0,11	0,11	0,14	Gre_dis_stdv	-0,12	-0,10	-0,13
CHM_con_med	0,05	0,10	0,10	Gre_ent_sum	0,34	0,18	0,31
CHM_con_stdv	0,01	0,03	0,04	Gre_ent_med	0,18	0,21	0,17
CHM_con_max	0,03	0,05	0,06	Gre_ent_stdv	-0,16	-0,19	-0,14
CHM_dis_sum	0,16	0,16	0,20	Gre_2m_sum	0,19	0,03	0,17
CHM_dis_med	0,07	0,12	0,12	Gre_2m_med	-0,18	-0,21	-0,16
CHM_dis_stdv	0,02	0,02	0,05	Gre_2m_stdv	-0,15	-0,19	-0,14
CHM_dis_max	0,05	0,08	0,09	Blue_var_sum	0,57	0,42	0,58
CHM_ent_sum	0,26	0,20	0,27	Blue_var_med	0,54	0,43	0,55
CHM_ent_med	0,10	0,16	0,14	Blue_var_stdv	0,40	0,37	0,42
CHM_ent_stdv	-0,06	-0,08	-0,07	Blue_hom_sum	-0,10	-0,17	-0,09
CHM_ent_max	0,06	0,10	0,10	Blue_hom_med	-0,22	-0,24	-0,20
CHM_2m_sum	0,03	-0,08	-0,02	Blue_hom_stdv	-0,09	-0,10	-0,10
CHM_2m_med	-0,10	-0,15	-0,13	Blue_con_sum	0,13	0,15	0,10
CHM_2m_stdv	-0,08	-0,10	-0,09	Blue_con_med	0,05	0,11	0,02
CHM_2m_max	-0,07	-0,11	-0,09	Blue_con_stdv	-0,05	0,00	-0,07
MDS_var_sum	0,10	0,00	0,07	Blue_dis_sum	0,25	0,23	0,22
MDS_var_med	0,03	-0,04	0,00	Blue_dis_med	0,12	0,18	0,09
MDS_var_stdv	0,05	-0,05	0,05	Blue_dis_stdv	-0,07	-0,03	-0,08
MDS_var_max	0,02	-0,05	0,00	Blue_ent_sum	0,35	0,19	0,32
MDS_hom_sum	0,21	0,09	0,16	Blue_ent_med	0,19	0,22	0,18
MDS_hom_med	-0,09	-0,06	-0,13	Blue_ent_stdv	-0,17	-0,19	-0,16
MDS_hom_stdv	0,07	0,02	0,09	Blue_2m_sum	0,15	0,00	0,13
MDS_hom_max	-0,03	-0,01	-0,06	Blue_2m_med	-0,19	-0,22	-0,18
MDS_con_sum	0,12	0,05	0,15	Blue_2m_stdv	-0,17	-0,20	-0,16
MDS_con_med	0,08	0,03	0,11				
MDS_con_stdv	0,05	-0,01	0,06				
MDS_con_max	0,06	-0,01	0,07				
MDS_dis_sum	0,15	0,08	0,18				
MDS_dis_med	0,09	0,05	0,13				
MDS_dis_stdv	0,07	0,01	0,09				
MDS_dis_max	0,09	0,02	0,12				
MDS_ent_sum	0,20	0,12	0,23				
MDS_ent_med	0,12	0,09	0,16				
MDS_ent_stdv	-0,03	-0,02	-0,04				
MDS_ent_max	0,09	0,05	0,13				
MDS_2m_sum	0,00	-0,03	-0,05				
MDS_2m_med	-0,12	-0,09	-0,16				
MDS_2m_stdv	-0,07	-0,04	-0,09				
MDS_2m_max	-0,09	-0,04	-0,12				

Correlação de Pearson entre dap, altura e volume e demais variáveis – talhão

Pinus 2 – câmera NIR

Variável	dap	h	vol	Variável	dap	h	vol
Area	0,32	0,15	0,29	Red_var_sum	0,53	0,37	0,53
CHM_sum	0,57	0,53	0,60	Red_var_med	0,48	0,36	0,48
CHM_med	0,56	0,66	0,62	Red_var_stdv	0,22	0,17	0,24
CHM_stdv	0,17	0,22	0,22	Red_hom_sum	0,29	0,16	0,30
CHM_max	0,51	0,63	0,59	Red_hom_med	0,19	0,12	0,21
MDS_sum	0,32	0,15	0,29	Red_hom_stdv	0,12	0,07	0,14
MDS_med	0,03	-0,04	0,00	Red_con_sum	-0,17	-0,11	-0,20
MDS_stdv	0,08	0,04	0,12	Red_con_med	-0,27	-0,16	-0,28
MDS_max	0,03	-0,04	0,01	Red_con_stdv	-0,13	-0,09	-0,13
Red_sum	0,57	0,38	0,55	Red_dis_sum	-0,08	-0,07	-0,12
Red_med	0,53	0,42	0,53	Red_dis_med	-0,26	-0,16	-0,28
Red_stdv	-0,14	-0,05	-0,15	Red_dis_stdv	-0,05	-0,03	-0,04
Gre_sum	0,56	0,38	0,55	Red_ent_sum	0,29	0,14	0,26
Gre_med	0,53	0,41	0,53	Red_ent_med	-0,16	-0,07	-0,18
Gre_stdv	-0,13	-0,04	-0,13	Red_ent_stdv	0,14	0,07	0,16
NIR_sum	0,56	0,37	0,55	Red_2m_sum	0,34	0,16	0,32
NIR_med	0,54	0,42	0,53	Red_2m_med	0,16	0,07	0,17
NIR_stdv	-0,19	-0,08	-0,19	Red_2m_stdv	0,13	0,06	0,14
Intens_sum	0,56	0,38	0,55	Gre_var_sum	0,52	0,36	0,52
Intens_med	0,53	0,42	0,53	Gre_var_med	0,47	0,36	0,48
Intens_stdv	-0,14	-0,05	-0,14	Gre_var_stdv	0,22	0,16	0,24
CHM_var_sum	0,58	0,59	0,63	Gre_hom_sum	0,28	0,15	0,29
CHM_var_med	0,53	0,64	0,60	Gre_hom_med	0,17	0,10	0,20
CHM_var_stdv	0,23	0,26	0,30	Gre_hom_stdv	0,11	0,06	0,13
CHM_var_max	0,49	0,60	0,58	Gre_con_sum	-0,17	-0,11	-0,19
CHM_hom_sum	0,16	0,01	0,10	Gre_con_med	-0,26	-0,16	-0,28
CHM_hom_med	-0,07	-0,12	-0,12	Gre_con_stdv	-0,13	-0,09	-0,13
CHM_hom_stdv	-0,01	-0,01	0,01	Gre_dis_sum	-0,07	-0,06	-0,11
CHM_hom_max	-0,03	-0,09	-0,07	Gre_dis_med	-0,25	-0,15	-0,27
CHM_con_sum	0,10	0,11	0,14	Gre_dis_stdv	-0,05	-0,03	-0,04
CHM_con_med	0,04	0,09	0,09	Gre_ent_sum	0,29	0,15	0,26
CHM_con_stdv	0,01	0,02	0,03	Gre_ent_med	-0,15	-0,03	-0,16
CHM_con_max	0,03	0,04	0,06	Gre_ent_stdv	0,15	0,04	0,16
CHM_dis_sum	0,16	0,15	0,20	Gre_2m_sum	0,33	0,14	0,32
CHM_dis_med	0,06	0,11	0,11	Gre_2m_med	0,15	0,03	0,16
CHM_dis_stdv	0,00	0,01	0,02	Gre_2m_stdv	0,14	0,03	0,15
CHM_dis_max	0,04	0,06	0,08	NIR_var_sum	0,53	0,36	0,53
CHM_ent_sum	0,27	0,23	0,29	NIR_var_med	0,47	0,36	0,48
CHM_ent_med	0,11	0,18	0,16	NIR_var_stdv	0,21	0,16	0,23
CHM_ent_stdv	-0,05	-0,09	-0,07	NIR_hom_sum	0,30	0,17	0,30
CHM_ent_max	0,09	0,14	0,13	NIR_hom_med	0,20	0,13	0,22
CHM_2m_sum	0,02	-0,10	-0,03	NIR_hom_stdv	0,13	0,09	0,15
CHM_2m_med	-0,10	-0,17	-0,15	NIR_con_sum	-0,19	-0,12	-0,20
CHM_2m_stdv	-0,06	-0,11	-0,09	NIR_con_med	-0,28	-0,17	-0,29
CHM_2m_max	-0,06	-0,12	-0,10	NIR_con_stdv	-0,14	-0,09	-0,13
MDS_var_sum	0,10	-0,01	0,06	NIR_dis_sum	-0,10	-0,08	-0,13
MDS_var_med	0,03	-0,04	0,00	NIR_dis_med	-0,28	-0,17	-0,30
MDS_var_stdv	0,05	-0,05	0,06	NIR_dis_stdv	-0,06	-0,04	-0,05
MDS_var_max	0,03	-0,05	0,00	NIR_ent_sum	0,30	0,15	0,27
MDS_hom_sum	0,19	0,09	0,14	NIR_ent_med	-0,12	-0,04	-0,14
MDS_hom_med	-0,11	-0,05	-0,15	NIR_ent_stdv	0,10	0,03	0,12
MDS_hom_stdv	0,08	0,01	0,09	NIR_2m_sum	0,32	0,15	0,31
MDS_hom_max	-0,07	-0,03	-0,10	NIR_2m_med	0,11	0,03	0,13
MDS_con_sum	0,12	0,04	0,15	NIR_2m_stdv	0,10	0,02	0,12
MDS_con_med	0,09	0,01	0,11				
MDS_con_stdv	0,05	-0,01	0,06				
MDS_con_max	0,06	-0,02	0,07				
MDS_dis_sum	0,16	0,07	0,19				
MDS_dis_med	0,11	0,04	0,14				
MDS_dis_stdv	0,08	0,00	0,09				
MDS_dis_max	0,10	0,01	0,12				
MDS_ent_sum	0,22	0,13	0,26				
MDS_ent_med	0,15	0,09	0,19				
MDS_ent_stdv	0,01	0,01	0,00				
MDS_ent_max	0,14	0,08	0,17				
MDS_2m_sum	-0,02	-0,03	-0,08				
MDS_2m_med	-0,14	-0,09	-0,18				
MDS_2m_stdv	-0,06	-0,03	-0,08				
MDS_2m_max	-0,09	-0,04	-0,13				

Correlação de Pearson entre dap, altura e volume e demais variáveis – talhão

Pinus 2 – câmara Multi

Variável	dap	h	vol	Variável	dap	h	vol	Variável	dap	h	vol
Area	0,31	0,15	0,29	MDS_ent_med	-0,03	-0,11	-0,01	RE_con_med	-0,32	-0,26	-0,34
CHM_sum	0,47	0,42	0,49	MDS_ent_stdv	0,02	-0,01	0,03	RE_con_stdv	-0,17	-0,15	-0,18
CHM_med	0,40	0,52	0,46	MDS_ent_max	0,00	-0,07	0,02	RE_dis_sum	-0,15	-0,16	-0,18
CHM_stdv	0,10	0,03	0,13	MDS_2m_sum	0,17	0,17	0,14	RE_dis_med	-0,32	-0,24	-0,34
CHM_max	0,38	0,48	0,45	MDS_2m_med	0,03	0,11	0,01	RE_dis_stdv	-0,09	-0,10	-0,09
MDS_sum	0,31	0,14	0,29	MDS_2m_stdv	0,02	0,00	0,03	RE_ent_sum	0,24	0,11	0,21
MDS_med	0,01	-0,05	-0,02	MDS_2m_max	0,07	0,15	0,07	RE_ent_med	-0,20	-0,11	-0,22
MDS_stdv	-0,05	-0,16	-0,04	Red_var_sum	0,31	0,19	0,29	RE_ent_stdv	0,16	0,09	0,17
MDS_max	0,00	-0,07	-0,03	Red_var_med	0,23	0,16	0,22	RE_2m_sum	0,34	0,16	0,33
Red_sum	0,40	0,24	0,38	Red_var_stdv	0,13	0,11	0,14	RE_2m_med	0,19	0,10	0,21
Red_med	0,29	0,21	0,27	Red_hom_sum	0,29	0,13	0,29	RE_2m_stdv	0,14	0,07	0,16
Red_stdv	-0,01	0,07	-0,01	Red_hom_med	0,15	0,07	0,17				
Gre_sum	0,43	0,26	0,40	Red_hom_stdv	0,03	0,02	0,04				
Gre_med	0,33	0,23	0,31	Red_con_sum	-0,11	-0,06	-0,13				
Gre_stdv	-0,07	-0,03	-0,07	Red_con_med	-0,18	-0,09	-0,20				
NIR_sum	0,42	0,27	0,39	Red_con_stdv	-0,09	-0,05	-0,10				
NIR_med	0,32	0,27	0,30	Red_dis_sum	-0,04	-0,02	-0,06				
NIR_stdv	-0,15	-0,10	-0,15	Red_dis_med	-0,18	-0,09	-0,20				
RE_sum	0,41	0,26	0,38	Red_dis_stdv	-0,05	-0,02	-0,05				
RE_med	0,30	0,25	0,28	Red_ent_sum	0,26	0,14	0,23				
RE_stdv	-0,17	-0,11	-0,17	Red_ent_med	-0,07	0,02	-0,09				
NDVI_sum	0,30	0,14	0,27	Red_ent_stdv	0,05	-0,02	0,07				
NDVI_med	-0,07	-0,01	-0,06	Red_2m_sum	0,24	0,07	0,23				
NDVI_stdv	0,03	0,02	0,02	Red_2m_med	0,07	-0,02	0,09				
NDRE_sum	0,12	0,06	0,12	Red_2m_stdv	0,04	-0,03	0,06				
NDRE_med	0,00	0,01	0,01	Gre_var_sum	0,35	0,20	0,33				
NDRE_stdv	-0,20	-0,20	-0,21	Gre_var_med	0,27	0,17	0,26				
CHM_var_sum	0,47	0,47	0,50	Gre_var_stdv	0,13	0,09	0,15				
CHM_var_med	0,38	0,50	0,44	Gre_hom_sum	0,31	0,20	0,31				
CHM_var_stdv	0,09	0,04	0,13	Gre_hom_med	0,19	0,15	0,20				
CHM_var_max	0,34	0,45	0,41	Gre_hom_stdv	0,09	0,04	0,09				
CHM_hom_sum	0,18	0,09	0,13	Gre_con_sum	-0,14	-0,16	-0,17				
CHM_hom_med	-0,10	-0,03	-0,13	Gre_con_med	-0,22	-0,20	-0,25				
CHM_hom_stdv	0,04	-0,01	0,04	Gre_con_stdv	-0,10	-0,11	-0,11				
CHM_hom_max	-0,03	-0,02	-0,06	Gre_dis_sum	-0,07	-0,11	-0,10				
CHM_con_sum	0,13	0,04	0,16	Gre_dis_med	-0,23	-0,20	-0,25				
CHM_con_med	0,07	0,01	0,11	Gre_dis_stdv	-0,03	-0,07	-0,04				
CHM_con_stdv	0,04	-0,02	0,06	Gre_ent_sum	0,26	0,12	0,23				
CHM_con_max	0,04	-0,02	0,07	Gre_ent_med	-0,13	-0,07	-0,15				
CHM_dis_sum	0,18	0,07	0,21	Gre_ent_stdv	0,11	0,05	0,12				
CHM_dis_med	0,09	0,03	0,13	Gre_2m_sum	0,31	0,15	0,30				
CHM_dis_stdv	0,04	-0,02	0,05	Gre_2m_med	0,13	0,07	0,15				
CHM_dis_max	0,07	-0,01	0,10	Gre_2m_stdv	0,11	0,05	0,12				
CHM_ent_sum	0,24	0,11	0,26	NIR_var_sum	0,35	0,25	0,34				
CHM_ent_med	0,12	0,06	0,16	NIR_var_med	0,27	0,22	0,26				
CHM_ent_stdv	-0,02	0,01	-0,02	NIR_var_stdv	0,09	0,06	0,11				
CHM_ent_max	0,09	0,05	0,14	NIR_hom_sum	0,37	0,22	0,36				
CHM_2m_sum	0,01	0,00	-0,04	NIR_hom_med	0,25	0,18	0,26				
CHM_2m_med	-0,11	-0,05	-0,15	NIR_hom_stdv	0,08	0,06	0,09				
CHM_2m_stdv	-0,06	-0,01	-0,08	NIR_con_sum	-0,22	-0,19	-0,23				
CHM_2m_max	-0,06	-0,02	-0,09	NIR_con_med	-0,30	-0,23	-0,31				
MDS_var_sum	0,07	-0,02	0,04	NIR_con_stdv	-0,16	-0,13	-0,15				
MDS_var_med	0,01	-0,05	-0,02	NIR_dis_sum	-0,14	-0,14	-0,16				
MDS_var_stdv	-0,03	-0,16	-0,04	NIR_dis_med	-0,31	-0,23	-0,31				
MDS_var_max	0,00	-0,07	-0,03	NIR_dis_stdv	-0,09	-0,07	-0,08				
MDS_hom_sum	0,29	0,19	0,26	NIR_ent_sum	0,23	0,10	0,20				
MDS_hom_med	0,03	0,11	0,02	NIR_ent_med	-0,20	-0,11	-0,20				
MDS_hom_stdv	0,01	-0,04	0,02	NIR_ent_stdv	0,15	0,09	0,16				
MDS_hom_max	0,06	0,12	0,06	NIR_2m_sum	0,34	0,16	0,32				
MDS_con_sum	0,01	-0,10	0,01	NIR_2m_med	0,19	0,10	0,19				
MDS_con_med	-0,03	-0,11	-0,02	NIR_2m_stdv	0,13	0,07	0,14				
MDS_con_stdv	0,00	-0,06	0,00	RE_var_sum	0,34	0,23	0,32				
MDS_con_max	0,01	-0,08	0,00	RE_var_med	0,24	0,19	0,23				
MDS_dis_sum	0,01	-0,09	0,02	RE_var_stdv	0,08	0,06	0,10				
MDS_dis_med	-0,03	-0,11	-0,02	RE_hom_sum	0,36	0,22	0,36				
MDS_dis_stdv	0,01	-0,05	0,02	RE_hom_med	0,25	0,18	0,27				
MDS_dis_max	0,01	-0,07	0,02	RE_hom_stdv	0,08	0,04	0,09				
MDS_ent_sum	0,02	-0,09	0,04	RE_con_sum	-0,23	-0,21	-0,26				

APÊNDICE 2 – EQUAÇÕES DE DAP, ALTURA E VOLUME

Equações para dap - Talhão *Eucalyptus*

N°	Equações – Câmera NIR
1	$dap = -47,5842 + 7,1104 \cdot Area - 0,066045 \cdot CHM_sum + 2,59769 \cdot CHM_med + 0,848751 \cdot CHM_stdv + 1,1979 \cdot MDS_stdv$
2	$dap = 24,1799 + 0,354406 \cdot Red_med - 1,79474 \cdot Red_stdv - 9,13868 \cdot Gre_stdv + 0,0018298 \cdot NIR_sum - 0,258964 \cdot NIR_mean - 1,15313 \cdot NIR_stdv + 12,253 \cdot Intens_stdv$
3	$dap = 22,0932 + 0,00140842 \cdot Red_var_sum + 0,0473459 \cdot Gre_var_med + 0,0978824 \cdot Gre_var_stdv + 1,18484 \cdot Gre_dis_stdv - 0,026083 \cdot NIR_var_med - 0,026456 \cdot NIR_var_stdv - 0,323589 \cdot NIR_hom_sum - 0,151341 \cdot NIR_con_stdv - 3,0814 \cdot NIR_dis_med + 3,46159 \cdot NIR_dis_stdv + 0,0750278 \cdot NIR_ent_sum$
4	$dap = 0,0504953 \cdot CHM_var_med + 0,0718449 \cdot CHM_var_stdv - 0,0204551 \cdot CHM_var_max - 0,00500193 \cdot MDS_con_sum + 0,66941 \cdot MDS_dis_max + 0,19238 \cdot MDS_ent_sum + 0,287971 \cdot MDS_2m_sum$
5	$dap = -22,4261 + 0,832153 \cdot CHM_med + 1,97967 \cdot CHM_stdv + 0,561969 \cdot MDS_stdv + 0,0249815 \cdot MDS_max - 0,00866589 \cdot Red_sum + 0,0120571 \cdot Gre_sum + 0,102291 \cdot Gre_med - 0,0989288 \cdot NIR_med - 0,0306442 \cdot NIR_stdv$
6	$dap = 6,70785 + 0,000937123 \cdot CHM_var_sum + 0,0773001 \cdot CHM_var_stdv + 3,34378 \cdot MDS_hom_med + 9,21703 \cdot MDS_hom_stdv + 5,97965 \cdot MDS_ent_stdv - 12,5605 \cdot MDS_2m_stdv + 0,0208203 \cdot Red_var_stdv - 0,0383334 \cdot Red_dis_sum + 0,0594353 \cdot Gre_var_med + 1,06111 \cdot Gre_dis_stdv - 0,0154639 \cdot NIR_var_med - 5,14108 \cdot NIR_hom_stdv - 0,134404 \cdot NIR_con_med + 1,60144 \cdot NIR_dis_stdv$
7	$dap = 0,0265935 \cdot CHM_sum - 0,176328 \cdot Red_med + 0,262319 \cdot Red_stdv + 0,284012 \cdot Gre_med - 0,305194 \cdot Gre_stdv + 0,0719638 \cdot CHM_var_stdv - 1,4155 \cdot CHM_hom_max + 3,15579 \cdot MDS_hom_med + 8,33885 \cdot MDS_hom_stdv + 7,0208 \cdot MDS_ent_stdv - 14,1481 \cdot MDS_2m_stdv + 0,351459 \cdot Red_2m_sum + 0,04319 \cdot Gre_var_stdv - 0,000388074 \cdot NIR_var_sum - 4,27445 \cdot NIR_hom_med - 0,0674001 \cdot NIR_dis_sum + 1,54153 \cdot NIR_dis_stdv$
Equações – Câmera Multi	
1	$dap = 34,8623 + 0,0827754 \cdot CHM_sum - 1,18882 \cdot CHM_med + 1,59296 \cdot CHM_stdv - 0,00144061 \cdot MDS_sum + 0,434237 \cdot MDS_stdv$
2	$dap = -58,2956 + 4,98347 \cdot Gre_sum + 269,899 \cdot Gre_stdv - 25,0528 \cdot Red_sum + 1056,5 \cdot Red_med - 1,08002 \cdot NIR_sum - 68,7988 \cdot NIR_stdv + 1,03226 \cdot NDVI_sum + 57,4268 \cdot NDVI_med + 56,7578 \cdot NDVI_stdv + 15,9434 \cdot NDRE_med - 53,61 \cdot NDRE_stdv$
3	$dap = 19,8798 + 0,00644966 \cdot Gre_var_sum - 0,0514007 \cdot Gre_con_sum - 0,0198308 \cdot Red_var_sum + 0,556468 \cdot Red_var_stdv + 7,09079 \cdot Red_ent_med + 0,436149 \cdot Red_2m_sum + 0,0410525 \cdot RE_var_stdv - 3,15168 \cdot RE_dis_med + 0,000165157 \cdot NIR_var_sum - 0,0439386 \cdot NIR_var_stdv - 7,60785 \cdot NIR_hom_med + 4,55049 \cdot NIR_hom_stdv + 0,288544 \cdot NIR_con_stdv - 2,54628 \cdot NIR_ent_med$
4	$dap = -27,2792 + 0,0425459 \cdot CHM_var_med + 0,0526893 \cdot CHM_var_stdv - 0,0157285 \cdot CHM_var_max + 0,255583 \cdot CHM_dis_max + 0,0206743 \cdot MDS_var_med - 0,021442 \cdot MDS_var_max + 1,12727 \cdot MDS_hom_sum - 0,986572 \cdot MDS_con_med - 0,301564 \cdot MDS_dis_sum + 21,3079 \cdot MDS_dis_med + 0,407764 \cdot MDS_dis_max + 5,80856 \cdot MDS_ent_med - 0,915833 \cdot MDS_2m_sum + 28,8233 \cdot MDS_2m_med$
5	$dap = -42,5548 + 0,0331505 \cdot CHM_sum + 1,82303 \cdot CHM_stdv - 0,0293631 \cdot MDS_med + 0,27947 \cdot MDS_stdv + 109,859 \cdot Gre_med - 25,382 \cdot Red_sum + 1083,52 \cdot Red_med + 151,949 \cdot RE_med - 48,8123 \cdot RE_stdv - 123,704 \cdot NIR_med + 62,1196 \cdot NDVI_med + 29,9454 \cdot NDVI_stdv + 76,6153 \cdot NDRE_med - 39,357 \cdot NDRE_stdv$
6	$dap = 0,198227 \cdot Gre_var_stdv - 0,250491 \cdot Gre_con_sum + 5,22769 \cdot Gre_con_med - 2,41535 \cdot Gre_2m_stdv - 1,83654 \cdot Red_2m_med + 0,156543 \cdot RE_hom_sum - 0,32999 \cdot RE_con_med + 0,152379 \cdot RE_con_stdv - 0,100501 \cdot RE_ent_sum + 0,0095441 \cdot NIR_var_med + 0,241198 \cdot NIR_con_med + 0,0420527 \cdot CHM_var_med + 0,0460686 \cdot CHM_var_stdv - 0,0198415 \cdot CHM_var_max - 2,02099 \cdot CHM_hom_max + 0,196782 \cdot CHM_dis_max + 0,0159936 \cdot MDS_var_med - 0,0171065 \cdot MDS_var_max + 0,226528 \cdot MDS_ent_sum + 4,90619 \cdot MDS_ent_med + 0,592403 \cdot MDS_2m_sum$
7	$dap = -25,036 - 220,52 \cdot Gre_stdv - 124,555 \cdot RE_stdv + 3,49286 \cdot NIR_sum + 49,8933 \cdot NDRE_med - 19,3185 \cdot NDRE_stdv + 0,251878 \cdot Gre_var_stdv - 1,65725 \cdot Red_2m_med + 0,0444294 \cdot RE_var_med + 0,0932284 \cdot RE_var_stdv - 1,67982 \cdot RE_dis_med - 0,089896 \cdot RE_ent_sum - 0,00464724 \cdot NIR_var_sum + 0,211438 \cdot NIR_con_med + 0,000814782 \cdot CHM_var_sum + 0,0181904 \cdot CHM_var_stdv + 0,215691 \cdot CHM_dis_max + 0,0137037 \cdot MDS_var_med - 0,0144783 \cdot MDS_var_max + 10,2037 \cdot MDS_hom_med - 0,0166182 \cdot MDS_con_sum + 5,84397 \cdot MDS_dis_med + 9,6179 \cdot MDS_ent_med + 13,6789 \cdot MDS_2m_med$

Equações para altura - Talhão *Eucalyptus*

N°	Equações – Câmera NIR
1	Altura = -24,0782 + 0,265115*Area + 0,839721*CHM_Med + 0,404838*MDS_Med - 0,379174*MDS_max
2	Altura = 8,45125 + 0,24922*Gre_stde=v + 0,000479662*NIR_sum + 0,0485694*NIR_med - 0,189212*NIR_stdv
3	Altura = 13,0031 + 0,0683325*Red_var_med - 0,0973485*Red_var_stdv + 0,0655668*Red_hom_sum - 0,112631*Gre_var_med + 0,206353*Gre_var_stdv + 0,00508168*Gre_con_sum - 0,186237*Gre_con_med + 2,39215*Gre_dis_stdv + 0,0211565*NIR_var_med - 0,0306983*NIR_var_stdv - 0,13894*NIR_con_stdv - 11,7838*NIR_2m_med
4	Altura = 9,48275 + 0,0294255*CHM_var_med - 0,00261845*CHM_con_sum + 0,0000353415*MDS_var_sum + 0,0501433*MDS_hom_sum + 0,0734489*MDS_con_stdv
5	Altura = -27,1288 + 1,03161*CHM_med + 0,977193*CHM_stdv - 0,258572*CHM_max + 0,547864*MDS_med - 0,522902*MDS_max - 0,151394*Red_stdv + 0,165213*Gre_stdv + 0,000364172*NIR_sum + 0,0220413*NIR_med
6	Altura = 9,42237 + 0,0404151*CHM_var_med + 0,0492106*CHM_var_stdv - 0,0148105*CHM_var_max + 0,0175483*MDS_var_med - 0,0164722*MDS_var_max + 0,00156709*Red_var_sum - 0,0723295*Red-var_stdv - 0,0474063*Red_dis_sum - 0,00249493*Gre_var_sum + 0,0896354*Gre_var_stdv + 0,0027205*Gre_con_sum + 0,6049*Gre_dis_stdv + 0,00044246*NIR_var_sum - 0,0823441*NIR_hom_sum
7	Altura = -11,3438 + 0,984807*CHM_med - 0,258933*CHM_max - 0,234604*MDS_stdv + 0,0573273*NIR_med + 0,0308578*NIR_stdv + 0,0993571*Intens_med + 0,0373307*CHM_var_stdv + 0,0000206742*MDS_var_sum + 1,35331*MDS_hom_med + 0,0872956*Red_hom_sum - 0,0535153*Gre_var_med
Equações - Câmera Multi	
1	Altura = 12,1579 - 1,32342*Area + 0,0186134*CHM_sum + 0,371595*CHM_med - 0,207272*MDS_stdv
2	Altura = -46,5204 - 131,694*Gre_med + 14,705*Red_sum + 196,823*Red_stdv - 0,4422*NIR_sum - 9,38083*NIR_stdv + 77,2845*NDVI_med + 21,4504*NDVI_stdv - 28,6975*NDRE_stdv
3	Altura = 21,1427 - 0,208245*Gre_var_med + 0,219681*Gre_var_stdv - 0,0326177*Gre_con_sum + 0,743039*Gre_ent_med + 0,00064087*RE_var_sum - 0,168364*RE_con_med - 2,16453*NIR_hom_med + 0,289992*NIR_2m_sum
4	Altura = 14,9625 + 0,000374833*CHM_var_sum + 0,0230222*CHM_var_med + 0,0354507*CHM_var_stdv - 0,0115099*CHM_var_max - 0,280692*CHM_hom_sum + 0,232522*CHM_con_med - 0,0372902*CHM_con_max + 0,141898*CHM_dis_sum - 7,28482*CHM_dis_med + 0,59292*CHM_dis_max - 0,0160403*MDS_var_stdv + 3,90913*MDS_hom_max - 0,0219163*MDS_con_sum + 0,514506*MDS_con_med + 0,584841*MDS_ent_stdv
5	Altura = -55,0634 + 0,0311084*CHM_sum + 0,30858*CHM_stdv - 3,90296*Gre_sum + 420,707*Red_med - 1,74215*NIR_sum + 26,3511*NIR_med + 68,4588*NDVI_med + 24,3243*NDVI_stdv - 30,5236*NDRE_stdv
6	Altura = 16,2768 - 0,00451883*Gre_var_sum + 0,149944*Gre_var_stdv - 0,532576*Gre_con_med + 0,000349808*RE_var_sum - 0,00497514*RE_con_sum + 0,565407*NIR_dis_med - 1,12396*NIR_ent_med + 0,0307183*CHM_var_med + 0,0376857*CHM_var_stdv - 0,0127934*CHM_var_max - 5,38595*CHM_hom_med + 0,130685*CHM_con_med + 0,171839*CHM_dis_sum - 6,49394*CHM_dis_med - 0,00798571*MDS_var_stdv + 4,36889*MDS_hom_max - 0,0221982*MDS_con_sum + 0,541287*MDS_con_med
7	Altura = -273,992 + 0,417282*MDS_med - 0,19706*MDS_max + 10,0039*Red_sum - 28,1304*RE_stdv + 73,9966*NDVI_med + 28,6701*NDVI_stdv - 23,8558*NDRE_stdv + 0,0845209*Gre_var_stdv - 0,282751*Gre_con_sum + 6,22704*Gre_con_mean + 0,776123*gre6_med + 0,202382*Red_var_med - 0,779269*Red_ent_stdv + 0,0307114*RE_var_stdv + 0,298102*RE_2m_sum - 0,000869176*NIR_var_sum - 0,533633*NIR_dis_stdv + 0,414006*NIR_2m_sum - 8,99207*NIR_2m_stdv + 0,0173174*CHM_var_med + 0,0117226*CHM_var_stdv + 0,0169389*CHM_con_med + 0,000218426*MDS_var_sum - 0,0115432*MDS_var_med + 4,47219*MDS_hom_max

Equações para volume - Talhão *Eucalyptus*

N°	Equações – Câmera NIR
1	$Vol = -0,4983 + 0,000398368*CHM_sum + 0,0232784*CHM_med + 0,0326467*CHM_stdv + 0,0310603*MDS_stdv$
2	$Vol = 0,335949 + 0,00737834*Red_med + 0,0127959*Red_stdv - 0,00555248*NIR_med - 0,0110771*NIR_stdv + 0,000097371*Intens_sum$
3	$Vol = 0,427805 + 0,0000667974*Red_var_sum + 0,00383858*Gre_var_stdv + 0,0344211*Gre_dis_stdv - 0,000523122*NIR_var_med - 0,00107945*NIR_var_stdv - 0,00943094*NIR_hom_sum - 0,00476048*NIR_con_stdv - 0,0886282*NIR_dis_med + 0,105581*NIR_dis_stdv$
4	$Vol = -0,463911 + 0,00198644*CHM_var_med + 0,00287217*CHM_var_stdv - 0,000850462*CHM_var_max - 0,000114704*CHM_con_sum + 0,00675785*MDS_hom_sum + 0,27817*MDS_hom_stdv + 0,0143852*MDS_dis_max + 0,00366352*MDS_ent_sum + 0,0314367*MDS_ent_max + 0,135239*MDS_2m_med - 0,186383*MDS_2m_stdv$
5	$Vol = -0,411132 + 0,00122151*CHM_sum + 0,0573413*CHM_stdv + 0,0145221*MDS_stdv - 0,00592709*Red_med + 0,0107612*Gre_med - 0,0000953191*NIR_sum$
6	$Vol = 0,0000397978*CHM_var_sum + 0,00233385*CHM_var_stdv + 7,83771E-7*MDS_var_sum - 0,00016291*MDS_con_sum + 0,0153908*MDS_dis_max + 0,110119*MDS_ent_stdv - 0,227124*MDS_2m_stdv + 0,000531209*Red_var_stdv - 0,00464335*Red_hom_sum - 0,00280195*Red_dis_sum + 0,0000553081*Gre_var_sum + 0,0614488*Gre_dis_stdv - 0,0000152825*NIR_var_sum$
7	$Vol = -0,592952 + 0,0288488*CHM_med - 0,0732218*Red_stdv + 0,000136277*Gre_sum - 0,30652*Gre_stdv - 0,0314831*NIR_stdv + 0,414612*Intens_stdv + 0,00260951*CHM_var_stdv - 0,000115041*CHM_con_sum + 0,0050924*MDS_hom_sum + 0,242869*MDS_hom_stdv + 0,00969536*MDS_dis_max + 0,201144*MDS_ent_stdv - 0,447105*MDS_2m_stdv - 0,00161156*Red_dis_sum + 0,0102618*Red_2m_sum + 0,00111003*Gre_var_stdv - 0,0000167989*NIR_var_sum - 0,125933*NIR_hom_stdv + 0,045927*NIR_dis_stdv$
Equações – Câmera Multi	
1	$Vol = 1,98788 - 0,142987*Area + 0,0021115*CHM_sum - 0,0196955*CHM_med + 0,0521752*CHM_stdv - 0,00157021*MDS_med + 0,0103395*MDS_stdv$
2	$Vol = -1,76917 + 2,96715*Gre_med + 6,1578*Gre_stdv + 8,87796*Red_med + 8,37238*Red_stdv - 0,0407686*RE_sum - 2,67842*RE_stdv + 0,020202*NDVI_sum + 1,8283*NDVI_med + 1,0588*NDVI_stdv - 0,880693*NDRE_stdv$
3	$Vol = 0,000145871*Gre_var_sum - 0,00137979*Gre_con_sum - 0,000608343*Red_var_sum + 0,0176892*Red_var_stdv + 0,165133*Red_ent_med + 0,010295*Red_2m_sum + 0,00167233*RE_var_stdv + 0,00803897*RE_hom_sum - 0,0109192*RE_con_med - 0,00168762*NIR_var_stdv - 0,202119*NIR_hom_med + 0,0105798*NIR_con_stdv + 0,449596*NIR_2m_med$
4	$Vol = -0,472769 + 0,0000365571*CHM_var_sum + 0,00100324*CHM_var_stdv - 0,0284136*CHM_hom_sum + 0,683392*CHM_hom_med + 0,00649291*CHM_dis_max - 0,00000120691*MDS_var_sum + 0,0142907*MDS_hom_sum - 0,000605196*MDS_con_sum + 0,164236*MDS_dis_med + 0,0142632*MDS_dis_max + 0,00165287*MDS_ent_sum$
5	$Vol = -1,06895 + 0,0196177*CHM_med + 0,0439541*CHM_stdv + 0,00955504*CHM_max + 0,00850501*MDS_stdv + 0,139876*Gre_sum + 5,52299*Red_stdv - 1,76006*RE_stdv + 0,644723*NDVI_med + 0,637678*NDVI_stdv + 0,0199783*NDRE_sum - 0,971379*NDRE_stdv$
6	$Vol = 0,00562688*Gre_var_stdv - 0,00805699*Gre_con_sum + 0,163096*Gre_con_med - 0,0891763*Gre_2m_stdv - 0,0472926*Red_2m_med + 0,00552608*RE_hom_sum - 0,00753275*RE_con_med + 0,00357029*RE_con_stdv + 0,217784*RE_ent_stdv + 0,0297246*RE_2m_sum - 1,26888*RE_2m_stdv + 0,00000690569*NIR_var_sum + 0,00584212*NIR_con_med + 0,00145435*CHM_var_med + 0,00168464*CHM_var_stdv - 0,000642558*CHM_var_max - 0,0710858*CHM_hom_max - 0,00125794*CHM_con_stdv + 0,0114839*CHM_dis_max + 0,00000681429*MDS_var_sum - 0,000204436*MDS_var_max - 0,150919*MDS_hom_med$
7	$Vol = -1,93991 + 0,379346*Red_sum - 4,54251*RE_stdv + 0,0501578*NIR_sum + 1,72458*NDVI_med + 0,833781*NDVI_stdv + 0,577348*NDRE_med - 0,727431*NDRE_stdv + 0,00564858*Gre_var_stdv - 0,00083365*Gre_con_sum + 0,0181135*Red_ent_med + 0,00306598*RE_var_stdv + 0,00859572*RE_con_med - 0,0673651*RE_dis_med - 0,00328461*RE_ent_sum - 0,0000702187*NIR_var_sum + 0,0000299874*CHM_var_sum + 0,000548174*CHM_var_stdv - 0,0434434*CHM_hom_max + 0,00546671*CHM_dis_max + 0,000399546*MDS_var_mean - 0,000413369*MDS_var_max - 0,000569553*MDS_con_sum + 0,0137978*MDS_con_med + 0,256718*MDS_ent_med - 0,00715014*MDS_2m_sum + 0,534949*MDS_2m_med$

Equações para dap - Talhão *Pinus* 1

N°	Equações – Câmera RGB
1	$dap = 6,93948 + 0,0125392*CHM_sum + 0,481875*CHM_max$
2	$dap = 19,8404 + 0,514483*Red_stdv - 0,520062*Gre_stdv + 0,00243705*Blue_sum - 0,0449897*Blue_med$
3	$dap = 22,5873 + 0,00598999*Red_con_sum - 63,7227*Red_2m_med - 0,00611861*Gre_con_sum + 0,000481639*Blue_var_sum + 1,33294*Blue_2m_sum$
4	$dap = 16,8087 + 0,000981866*CHM_var_sum - 3,60598*CHM_2m_med$
5	$dap = 0,517665*Area + 0,993764*CHM_med + 0,940659*CHM_stdv + 0,000900453*Blue_sum - 0,0679397*Blue_stdv$
6 e 7	$dap = 19,9465 + 0,00101015*CHM_var_sum - 0,0636322*CHM_2m_sum + 0,000810428*Red_var_sum + 7,20987*Red_ent_med - 0,000518431*Gre_var_sum - 0,00107676*Gre_con_sum - 9,21544*Blue_ent_med$
	Equações – Câmera NIR
1	$dap = -16,1114 - 0,0175407*CHM_sum + 1,79923*CHM_med + 0,000532686*MDS_sum + 0,967013*MDS_stdv$
2	$dap = 20,8895 + 0,00856587*Red_sum - 0,0305602*NIR_med - 0,00621834*Intens_sum$
3	$dap = 22,9063 + 0,00426901*Red_var_sum - 0,00287278*Gre_var_sum - 3,51606*Gre_ent_med - 0,000494946*NIR_var_sum + 0,0858915*NIR_ent_sum$
4	$dap = 14,7823 + 0,0023204*CHM_var_sum - 0,110559*CHM_var_stdv - 0,0640282*CHM_2_sum + 1,70921*MDS_ent_med$
5	$dap = 0,87767*CHM_med + 0,000106308*MDS_sum + 0,000683127*NIR_sum$
6	$dap = 19,7923 + 0,00161429*CHM_var_sum + 0,0387498*MDS_ent_sum + 0,0137647*Red_var_med - 2,79631*Gre_ent_med$
7	$dap = 23,8119 + 0,0387574*Red_med + 0,00166106*CHM_var_sum - 0,149188*CHM_var_stdv - 3,08179*CHM_2m_med + 0,0384964*MDS_ent_sum - 4,19845*Gre_ent_med$
	Equações – Câmera Multi
1	$dap = 7,21405 + 0,0128167*CHM_sum + 0,477873*CHM_max$
2	$dap = 10,2343 + 10,3076*Red_sum - 32,0707*NIR_stdv + 10,7277*NDVI_med - 69,6979*NDRE_stdv$
3	$dap = 38,5894 + 0,00185371*Gre_var_sum - 0,0227069*Gre_con_sum + 0,327837*Gre_con_stdv + 4,04777*Gre_dis_med - 0,0386015*NIR_var_stdv + 0,335205*RE_hom_sum - 35,2947*RE_hom_med + 0,020757*RE_con_sum - 9,69659*RE_dis_med$
4	$dap = 17,7503 + 0,000897881*CHM_var_sum - 5,57188*CHM_2m_med$
5	$dap = 1,53706*Area - 0,0208002*CHM_sum + 1,61014*CHM_med - 274,821*Gre_stdv + 7,56446*Red_sum - 8,23386*NDVI_med - 33,918*NDRE_stdv$
6	$dap = 20,9153 + 0,0670325*CHM_var_med - 0,0359799*CHM_var_max - 5,3057*CHM_2m_med + 0,0012955*Gre_var_sum + 0,444801*Gre_hom_sum - 21,7531*Gre_hom_med - 0,00802359*Gre_con_sum - 0,038422*NIR_var_stdv$
7	$dap = 6,05528 - 1,26007*CHM_stdv + 282,227*Red_med - 21,7571*NIR_stdv - 25,6758*NDRE_stdv - 0,00947974*Gre_con_sum + 1,42896*Gre_dis_med - 12,8158*NIR_2m_stdv + 0,000688699*CHM_var_sum + 5,07833*CHM_hom_max + 0,0802525*CHM_ent_sum$

Equações para altura - Talhão *Pinus* 1

N°	Equações – Câmera RGB
1	Altura = 0,868007*CHM_med + 0,0000514847*MDS_sum
2	Altura = 11,1705 + 0,000543204*Gre_sum + 0,0197126*Gre_med
3	Altura = 15,0035 - 0,00041978*Red_var_sum - 4,31858*Red_hom_med + 0,00472212*Red_con_sum + 0,000600371*Gre_var_sum - 0,00384439*Gre_con_sum - 0,00169439*Blue_con_sum
4	Altura = 10,3374 + 0,000205239*CHM_var_sum + 0,0712903*CHM_var_med + 0,121116*CHM_var_stdv - 0,0473836*CHM_var_max - 1,87672*CHM_ent_stdv + 0,0000458118*MDS_var_sum - 0,0618203*MDS_var_stdv - 1,47247*MDS_ent_stdv
5	Altura = -38,3407 + 0,79581*CHM_med + 0,0402938*MDS_med + 0,000386653*Red_sum + 0,0198991*Red_med + 0,0785003*Red_stdv - 0,14241*Blue_stdv
6	Altura = 6,75947 + 0,0494466*CHM_var_med - 0,0159112*CHM_var_max + 0,0303523*CHM_ent_sum - 0,725176*CHM_ent_max + 0,0000500907*MDS_var_sum + 0,000230508*Red_var_sum + 0,456697*Red_dis_med - 0,00243611*Blue_con_sum
7	Altura = -298,663 + 1,37488*CHM_med + 1,36524*CHM_stdv + 0,311229*MDS_med + 0,00216567*Red_sum - 0,0014652*Intens_sum - 0,0213241*CHM_var_max + 0,0377259*CHM_dis_sum - 0,843359*CHM_dis_max - 0,014741*MDS_var_max + 0,0286853*Red_con_med - 0,00187437*Blue_con_sum
Equações – Câmera NIR	
1	Altura = -2,7434 - 3,40889*Area + 0,990911*CHM_med + 0,00093828*MDS_sum
2	Altura = 10,6509 - 0,0270519*Red_sum + 1,49908*Red_med + 0,628311*Red_stdv - 0,0685207*NIR_stdv + 0,0275137*Intens_sum - 1,46254*Intens_med - 0,520887*Intens_stdv
3	Altura = 11,327 + 0,00262736*Red_var_sum + 0,110215*Red_var_stdv + 22,5973*Red_2m_med - 0,00244048*Gre_var_sum - 0,0493551*NIR_var_stdv - 0,0851791*NIR_hom_sum + 5,89511*NIR_hom_stdv - 41,5867*NIR_2m_stdv
4	Altura = 9,31207 + 0,000410507*CHM_var_sum + 0,106003*CHM_var_med - 0,036642*CHM_var_max + 0,0000371878*MDS_var_sum - 2,16733*MDS_2m_max
5	Altura = -41,2798 + 0,839666*CHM_med + 0,477914*MDS_med - 0,437937*MDS_max + 0,12596*Red_stdv + 0,000289408*NIR_sum + 0,0159685*NIR_med - 0,0962735*NIR_stdv
6	Altura = 2,80154 + 0,0750488*CHM_var_med + 0,000214527*MDS_var_sum + 0,0215295*MDS_var_med - 0,0262514*MDS_var_max - 3,51935*MDS_2m_stdv + 0,00169561*Red_var_sum + 7,43872*Red_hom_stdv + 20,8806*Red_2m_med - 0,00203916*Gre_var_sum + 1,19861*Gre_dis_med + 0,000225784*NIR_var_sum - 0,0904636*NIR_con_med - 0,626495*NIR_2m_sum
7	Altura = -370,45 + 0,83829*CHM_med + 0,392155*MDS_med + 0,000492213*NIR_sum - 0,0203451*MDS_var_max - 2,20538*MDS_2m_max + 6,15835*Red_hom_stdv + 11,8544*Red_2m_stdv - 0,0873523*Gre_hom_sum - 17,8383*NIR_2m_stdv
Equações - Câmera Multi	
1	Altura = -2,34407*Area + 0,874344*CHM_med + 1,28801*CHM_stdv + 0,00065919*MDS_sum - 1,28095*MDS_stdv
2	Altura = 16,4121 + 412,22*Red_stdv + 0,701679*RE_sum - 55,773*RE_stdv - 0,277814*NDRE_sum - 67,9478*NDRE_stdv
3	Altura = 22,1519 + 0,00103433*Gre_var_sum - 13,6692*Gre_hom_med - 1,8458*Gre_dis_med + 3,3198*NIR_hom_med - 1,38826*NIR_dis_stdv
4	Altura = 7,26034 + 0,0718939*CHM_var_med - 0,0372419*CHM_var_max + 0,0471215*CHM_ent_sum + 0,0464075*MDS_var_stdv - 1,12827*MDS_con_max
5	Altura = -28,7099 + 0,718905*CHM_med + 1,23641*CHM_stdv + 1,17065*MDS_med - 1,13311*MDS_max - 117,755*Gre_stdv + 2,13732*Red_sum + 5,19778*NIR_med - 16,9553*NDRE_med - 31,3323*NDRE_stdv
6	Altura = 8,53578 + 0,0625836*CHM_var_med - 0,0306629*CHM_var_max + 0,0483348*CHM_dis_sum + 0,0519919*MDS_var_stdv - 1,37377*MDS_con_max - 1,3335*Gre_dis_stdv - 0,00113404*NIR_var_sum + 0,00226056*RE_var_sum - 0,00319286*RE_con_sum
7	Altura = -179,624 + 0,788716*CHM_med + 1,14026*MDS_med - 0,944449*MDS_max + 3,33876*Red_sum - 11,9541*NDRE_med - 23,2978*NDRE_stdv - 1,01034*Gre_dis_stdv - 0,0247628*Red_ent_sum + 0,0275869*CHM_dis_sum + 0,077631*MDS_var_stdv - 0,0105978*MDS_var_max - 1,08337*MDS_con_max

Equações para volume - Talhão *Pinus 1*

Nº	Equações – Câmera RGB
1	$Vol = -0,425846 + 0,000384517*CHM_sum + 0,0516824*CHM_med + 0,073839*CHM_stdv - 0,0210285*CHM_max$
2	$Vol = 0,158414 - 0,0948235*Red_stdv - 0,447525*Gre_stdv + 0,0000737689*Blue_sum - 0,0491686*Blue_stdv + 0,595007*Intens_stdv$
3	$Vol = 0,320122 + 0,000266469*Red_con_sum - 2,11276*Red_2m_med + 0,0000122571*Gre_var_sum - 0,000272767*Gre_con_sum + 0,03713*Blue_2m_sum$
4	$Vol = 0,0000357278*CHM_var_sum + 0,00336036*CHM_var_med + 0,00557949*CHM_var_stdv - 0,00289657*CHM_var_max - 0,00338648*CHM_2m_sum$
5	$Vol = -0,459087 + 0,000386538*CHM_sum + 0,0303514*CHM_med + 0,0332045*CHM_stdv + 0,00556663*Red_med - 0,00400948*Gre_med - 0,00361419*Blue_stdv$
6	$Vol = 0,000058452*CHM_var_sum - 0,000435623*CHM_var_max - 0,00373199*CHM_2m_sum + 0,00119002*Red_var_med - 0,000698648*Gre_var_med - 0,000170961*Gre_con_sum + 0,00471429*Gre_con_med$
7	$Vol = 0,0000584521*CHM_var_sum - 0,000435628*CHM_var_max - 0,003732*CHM_2m_sum + 0,00119002*Red_var_med - 0,00069865*Gre_var_med - 0,000170962*Gre_con_sum + 0,00471431*Gre_con_med$
	Equações – Câmera NIR
1	$Vol = -0,801119 + 0,0507382*CHM_med + 0,0000668965*MDS_sum + 0,0375696*MDS_stdv$
2	$Vol = 0,0905215 + 0,000560336*Red_sum + 0,0374604*Red_stdv - 0,000488062*Intens_sum - 0,0369866*Intens_stdv$
3	$Vol = 0,114113 + 0,000145153*Red_var_sum + 0,00384773*Red_var_stdv - 0,000111481*Gre_var_sum + 0,0228749*Gre_2m_sum - 0,00000775233*NIR_var_sum - 0,00166777*NIR_var_stdv - 1,45261*NIR_2m_stdv$
4	$Vol = 0,118685 + 0,000107252*CHM_var_sum - 0,0014394*CHM_2m_sum - 0,00457858*MDS_hom_sum - 0,157439*MDS_2m_stdv$
5	$Vol = -1,57232 + 0,0393278*CHM_med + 0,00105063*MDS_max + 0,0000358449*NIR_sum$
6	$Vol = -0,0570118 + 0,0000845505*CHM_var_sum - 0,0028143*CHM_hom_sum + 0,00000227991*MDS_var_sum - 0,00178489*MDS_2m_sum + 0,00359925*Red_var_med - 0,0032807*Gre_var_med + 0,556833*Gre_2m_med$
7	$Vol = -0,367088 + 0,00476807*NIR_med + 0,0000843179*CHM_var_sum - 0,00600238*MDS_hom_sum + 0,0174895*Gre_2m_sum - 0,000692578*NIR_var_med$
	Equações – Câmera Multi
1	$Vol = -0,426148 + 0,000400673*CHM_sum + 0,0299792*CHM_max$
2	$Vol = 0,169064 + 0,20059*Gre_sum + 4,62629*Red_med - 2,00521*RE_stdv - 2,91013*NDRE_stdv$
3	$Vol = 0,113353 + 0,0000783955*Gre_var_sum - 0,00104042*Gre_con_sum + 0,0164484*Gre_con_stdv + 0,00469003*Gre_dis_sum - 0,0818727*NIR_dis_stdv - 0,000323511*RE_con_sum$
4	$Vol = -0,17481 + 0,0000100347*CHM_var_sum + 0,00355706*CHM_var_med - 0,00213096*CHM_var_max + 0,00340437*CHM_ent_sum - 0,040247*MDS_con_max + 0,00160174*MDS_ent_sum$
5	$Vol = -0,386347 + 0,036476*CHM_med + 0,0731628*CHM_stdv - 0,0617283*MDS_stdv - 10,6823*Gre_stdv + 0,320759*Red_sum - 1,53251*NDRE_stdv$
6	$Vol = 0,159321 + 0,0000366781*CHM_var_sum - 0,00151786*CHM_var_stdv - 0,004589*CHM_2m_sum + 0,00159634*Gre_var_med - 0,205315*Gre_hom_med - 0,000348554*Gre_con_sum - 0,00201641*NIR_var_stdv + 0,0000294704*RE_var_sum$
7	$Vol = -1,12372 + 0,00115868*MDS_med + 10,1838*Red_med - 0,798371*NIR_stdv + 0,0750158*RE_sum + 1,52116*NDVI_stdv - 1,46162*NDRE_stdv - 0,000146237*Gre_con_sum - 0,00165796*Red_ent_sum - 0,00492238*RE_var_med - 0,209338*RE_hom_med + 0,00276086*CHM_var_mean - 0,00113396*CHM_var_max - 0,00412728*CHM_2m_sum - 0,038796*MDS_con_max - 0,00239711*MDS_2m_sum$

Equações para dap - Talhão *Pinus 2*

N°	Equações – Câmera RGB
1	$dap = -31,6726 + 4,98368*Area - 0,0862715*CHM_sum + 5,08725*CHM_med + 3,41224*CHM_stdv - 1,2256*CHM_max$
2	$dap = -0,01003*Red_sum + 0,011347*Gre_sum + 0,0980343*Blue_med$
3	$dap = -0,00300401*Red_var_sum + 0,0292669*Red_var_stdv + 0,103096*Red_dis_sum + 0,187116*Red_ent_sum + 0,00213476*Gre_var_sum - 0,121563*Gre_con_med + 0,408426*Gre_dis_med + 0,0655771*Blue_var_med - 0,0633685*Blue_var_stdv + 0,135431*Blue_con_med - 0,124819*Blue_dis_sum$
4	$dap = 5,31278 + 0,00236837*CHM_var_sum - 0,509525*CHM_con_stdv + 0,06856*CHM_ent_sum - 1,22859*CHM_ent_max + 5,21313*MDS_hom_med - 0,161865*MDS_2m_sum$
5	$dap = -6,80011 + 2,14201*CHM_med + 0,878402*CHM_stdv - 0,890963*CHM_max - 0,143948*Red_med + 0,290327*Red_stdv + 0,175129*Gre_med + 0,00293152*Blue_sum - 0,102934*Blue_stdv - 0,260869*Intens_stdv$
6	$dap = -6,59371 + 0,108741*CHM_var_med + 0,0983694*CHM_var_stdv - 0,0685356*CHM_var_max - 0,523707*CHM_dis_max + 0,0589074*MDS_var_med + 0,0881655*MDS_var_stdv - 0,0593285*MDS_var_max + 7,72676*MDS_hom_max - 2,43192*MDS_2m_max - 0,00115334*Red_var_sum + 0,0652682*Red_dis_sum + 0,159354*Red_ent_sum + 0,0190755*Gre_var_med + 0,0260313*Gre_var_stdv - 0,00211786*Gre_con_sum + 0,00185679*Blue_var_sum - 0,0651742*Blue_var_stdv + 0,0432907*Blue_con_med - 0,0724237*Blue_dis_sum$
7	$dap = -15,38 + 3,22009*CHM_med + 2,26275*CHM_stdv - 0,000274722*MDS_sum + 0,0104014*Blue_sum - 0,0603411*CHM_var_max - 0,684176*CHM_dis_max + 0,604625*Red_dis_med - 0,00181512*Blue_var_sum - 0,0218777*Blue_var_stdv - 0,033339*Blue_dis_sum$
	Equações – Câmera NIR
1	$dap = -45,4031 - 0,0573015*CHM_sum + 4,56325*CHM_med + 3,03846*CHM_stdv - 1,01971*CHM_max + 0,000960041*MDS_sum + 2,17474*MDS_med + 2,13814*MDS_stdv - 2,15202*MDS_max$
2	$dap = 4,21425 + 0,000327373*Red_sum + 0,000139361*NIR_med - 0,000179985*NIR_stdv - 0,000311683*Intens_sum$
3	$dap = 0,00480768*Red_var_sum + 0,0484551*Red_var_med - 0,00677527*Red_con_sum - 0,00518971*Gre_var_sum + 0,0669493*Gre_dis_sum + 4,4368*Gre_ent_stdv - 0,0101798*NIR_var_med - 0,0615187*NIR_con_med + 1,03373*NIR_dis_stdv + 0,169664*NIR_ent_sum$
4	$dap = -1,82457 + 0,204498*CHM_var_med + 0,265937*CHM_var_stdv - 0,139807*CHM_var_max - 0,684993*CHM_con_stdv + 0,0804503*MDS_var_med + 0,0695791*MDS_var_stdv - 0,0785426*MDS_var_max + 0,364412*MDS_hom_sum + 5,17445*MDS_dis_stdv + 0,106978*MDS_ent_sum - 4,29571*MDS_2m_stdv$
5	$dap = -5,4766 + 0,0384305*CHM_sum + 2,05816*CHM_med + 3,96357*CHM_stdv - 1,45868*CHM_max - 1,45981*MDS_stdv + 0,00586611*Red_med - 0,000188629*Red_stdv - 0,00545558*Intens_med$
6	$dap = -2,44852 + 0,211129*CHM_var_med + 0,310325*CHM_var_stdv - 0,162532*CHM_var_max - 1,54657*CHM_dis_stdv + 0,0000620422*MDS_var_sum - 0,06532*MDS_var_stdv + 0,0411024*MDS_ent_sum + 0,0998576*Red_var_med + 1,00169*Red_2m_sum - 0,0667108*Gre_var_med - 0,0109893*NIR_var_med + 0,207025*NIR_hom_sum - 0,00567648*NIR_con_sum + 0,0656776*NIR_dis_sum + 0,67202*NIR_dis_stdv$
7	$dap = -21,243 + 5,47652*CHM_med + 2,31249*CHM_stdv - 0,418525*CHM_max - 1,23345*MDS_stdv + 0,00370326*Red_med - 0,00279897*Red_stdv + 0,0000240463*Gre_sum - 0,00316959*Intens_med + 0,0026943*Intens_stdv + 0,191653*CHM_var_stdv - 0,12352*CHM_var_max + 5,19536*Red_hom_stdv - 0,149076*Red_ent_sum - 0,0375587*Gre_var_med$
	Equações – Câmera Multi
1	$dap = -35,7034 + 6,16573*Area - 0,102373*CHM_sum + 5,31099*CHM_med + 3,52551*CHM_stdv - 1,42426*CHM_max - 1,79238*MDS_stdv$
2	$dap = -11,9705 - 46,4756*Red_sum + 1554,21*Red_med + 6,79734*Gre_sum - 69,208*RE_stdv + 0,995794*NDVI_sum + 17,779*NDRE_med - 30,1047*NDRE_stdv$
3	$dap = 13,5286 - 0,0046138*Red_var_sum + 0,151484*Red_var_med - 0,00824297*Red_con_sum + 0,450845*Red_ent_sum - 8,58582*Red_ent_med + 11,6176*Gre_2m_med + 0,042148*NIR_var_med - 4,29468*NIR_hom_med - 0,0954278*NIR_dis_sum - 0,00104929*RE_var_sum - 0,256839*RE_con_med + 1,65142*RE_dis_stdv$
4	$dap = 0,284151*CHM_var_med + 0,342459*CHM_var_stdv - 0,237349*CHM_var_max + 5,75327*CHM_hom_max + 1,85942*CHM_dis_med - 4,21081*CHM_dis_stdv + 0,360604*CHM_ent_sum - 6,80983*CHM_ent_med + 2,2328*MDS_2m_max$
5	$dap = 4,81471*Area - 0,0788866*CHM_sum + 4,05997*CHM_med + 1,79134*CHM_stdv - 0,98585*CHM_max + 6,29681*MDS_med + 8,20074*MDS_stdv - 6,32818*MDS_max + 215,214*Red_med - 670,214*Red_stdv + 106,146*Gre_med + 375,116*Gre_stdv + 58,8098*NIR_stdv - 103,409*RE_stdv + 60,2829*NDVI_stdv + 0,524191*NDRE_sum - 26,4705*NDRE_stdv$
6	$dap = 11,0798 - 0,00208125*CHM_var_sum + 0,277743*CHM_var_med + 0,284504*CHM_var_stdv - 0,193079*CHM_var_max - 7,21038*CHM_hom_med - 11,7258*CHM_hom_stdv + 6,94291*CHM_hom_max + 0,0298755*MDS_var_med - 0,03012*MDS_var_max + 0,0379694*MDS_ent_sum + 2,65134*MDS_2m_max + 0,0243643*Red_var_med - 0,0576276*Red_var_stdv + 0,00075075*Gre_var_sum + 0,0389236*NIR_var_stdv + 4,70304*NIR_2m_sum - 89,6361*NIR_2m_med - 18,1796*NIR_2m_stdv - 5,71427*RE_hom_med - 2,86212*RE_dis_med$
7	$dap = 6,68982*CHM_med + 3,11005*MDS_med + 4,83588*MDS_stdv - 3,14235*MDS_max + 43,6088*Gre_sum + 85,4507*NDVI_stdv + 10,2334*NDRE_med - 31,9257*NDRE_stdv - 0,0690173*CHM_var_med + 0,189356*CHM_var_stdv - 0,129106*CHM_var_max - 0,0661534*Red_con_sum + 1,27817*Red_con_med - 0,00539902*Gre_var_sum - 0,241973*Gre_hom_sum + 0,0246845*Gre_con_sum - 3,28759*Gre_dis_med + 0,0300737*NIR_var_stdv - 0,0386633*NIR_dis_sum - 0,167322*RE_con_med$

Equações para altura - Talhão Pinus 2

N°	Equações – Câmera RGB
1	Altura = 10,6927 + 1,19923*Area - 0,025235*CHM_sum + 1,83972*CHM_med + 1,94464*CHM_stdv - 0,378064*CHM_max + 0,722778*MDS_med - 0,739465*MDS_max
2	Altura = 5,39769 - 0,00248292*Red_sum - 0,0562313*Red_med + 0,204198*Red_stdv - 0,193824*Gre_stdv + 0,00284529*Blue_sum - 0,0377549*Blue_med + 0,124322*Intens_med
3	Altura = 7,965 - 0,0289448*Red_var_med + 0,0259739*Red_var_stdv + 0,0197694*Red_dis_sum + 0,0600878*Red_ent_sum - 11,7027*Red_2m_med + 0,020159*Gre_var_med - 0,0226596*Gre_var_stdv - 0,0569837*Gre_hom_sum - 0,0321043*Gre_con_stdv - 0,00126249*Blue_var_sum + 0,0507087*Blue_var_med + 0,0394904*Blue_con_stdv - 0,649449*Blue_dis_med
4	Altura = 4,39469 + 0,0588273*CHM_var_med + 0,0577585*CHM_var_stdv - 0,0323084*CHM_var_max + 0,0259428*CHM_ent_sum + 0,0270052*MDS_var_med + 0,0279885*MDS_var_stdv - 0,0272521*MDS_var_max + 1,66837*MDS_hom_max - 0,217823*MDS_con_max + 0,0293539*MDS_ent_sum - 0,264881*MDS_ent_max
5	Altura = 25,6495 + 1,04182*CHM_med + 1,22647*CHM_stdv - 0,298296*CHM_max + 0,0000872392*MDS_sum + 0,462456*MDS_med - 0,4901*MDS_max - 0,000501996*Red_sum + 0,0521227*Red_stdv + 0,0248052*Gre_med - 0,048323*Gre_stdv
6	Altura = 6,16965 + 0,0463058*CHM_var_med + 0,0268617*CHM_var_stdv - 0,0222414*CHM_var_max + 0,0223002*CHM_ent_sum + 0,0161975*MDS_var_med + 0,023935*MDS_var_stdv - 0,0168701*MDS_var_max + 1,80429*MDS_hom_max - 0,288522*MDS_dis_max + 0,0237432*MDS_ent_sum - 0,318051*MDS_ent_max - 14,2633*Red_2m_med - 0,0234674*Gre_con_stdv + 0,013424*Gre_dis_sum - 0,000621601*Blue_var_sum + 0,0208397*Blue_var_mean + 0,0270298*Blue_con_stdv - 0,429644*Blue_dis_med
7	Altura = 1,43646*CHM_med + 1,01347*CHM_stdv + 0,0180796*Red_stdv + 0,0312948*Blue_med - 0,0217693*CHM_var_max + 0,217533*CHM_2m_sum - 5,85786*CHM_2m_med - 0,000707948*MDS_var_max - 0,225725*MDS_dis_max - 0,00372172*Red_var_stdv - 12,9018*Red_2m_med - 0,15038*Gre_dis_stdv - 0,000145008*Blue_var_sum - 0,0973321*Blue_dis_med
	Equações – Câmera NIR
1	Altura = -4,2781 + 1,05769*Area - 0,0250498*CHM_sum + 1,80605*CHM_med + 1,50799*CHM_stdv - 0,216556*CHM_max - 0,962176*MDS_stdv
2	Altura = 6,94869 + 0,00207886*Red_med + 0,00000105892*NIR_sum - 0,00194389*Intens_med
3	Altura = 60,3634 + 0,0255631*Red_var_med - 0,0429742*Red_con_stdv - 0,000771113*Gre_var_sum + 0,686692*Gre_dis_stdv + 0,127136*Gre_ent_sum - 20,4927*Gre_ent_med - 111,763*Gre_2m_med - 0,000477174*NIR_con_sum - 9,54471*NIR_2m_stdv
4	Altura = 5,54488 + 0,0773462*CHM_var_med + 0,0780524*CHM_var_stdv - 0,0445693*CHM_var_max + 0,0278178*CHM_ent_sum - 0,47113*MDS_con_med
5	Altura = 8,798 - 0,00469138*CHM_sum + 0,991528*CHM_med + 1,21606*CHM_stdv + 0,690571*MDS_med - 0,698891*MDS_max + 0,0000378646*Red_sum + 0,0000335928*NIR_stdv - 0,0000347368*Intens_sum
6	Altura = 6,69872 + 0,0718305*CHM_var_med + 0,0835403*CHM_var_stdv - 0,0424177*CHM_var_max + 0,467958*CHM_ent_med - 0,0105609*MDS_var_stdv + 1,84598*MDS_dis_stdv - 0,893544*MDS_dis_max - 0,42366*MDS_2m_med + 0,000363107*Red_var_sum - 8,28245*Gre_2m_med - 0,00015379*NIR_var_sum
7	Altura = -3,17321 + 1,8589*CHM_med + 1,92133*CHM_stdv + 0,00000976438*Red_sum - 0,0310581*CHM_var_max - 0,0161006*MDS_con_sum - 0,000368912*Red_var_sum - 0,00129014*Red_con_sum - 0,0311879*Red_ent_sum - 0,306048*Gre_2m_sum + 0,92111*NIR_hom_med + 0,0268236*NIR_con_med
	Equações - Câmera Multi
1	Altura = 22,2595 + 1,59983*Area - 0,0307935*CHM_sum + 1,43557*CHM_med + 1,94274*MDS_med + 1,94313*MDS_stdv - 1,97257*MDS_max
2	Altura = -55,1898 - 16,7956*Red_sum + 1105,69*Red_med + 303,897*Red_stdv - 32,8983*NIR_stdv - 42,7695*RE_med + 0,370028*NDVI_sum + 66,6498*NDVI_med - 0,435768*NDRE_sum - 25,9376*NDRE_stdv
3	Altura = 12,7155 + 0,491135*Red_dis_med - 5,85206*Red_2m_med - 0,610451*Gre_dis_med - 1,30469*Gre_ent_stdv + 0,000491457*NIR_var_sum - 0,13403*NIR_con_med + 0,142193*NIR_con_stdv - 1,18222*RE_hom_med - 0,109863*RE_con_med
4	Altura = 4,92791 + 0,0712143*CHM_var_med + 0,0633954*CHM_var_stdv - 0,0469624*CHM_var_max - 0,309482*CHM_dis_max + 0,0329848*CHM_ent_sum + 0,445514*CHM_2m_max + 0,0142638*MDS_var_med + 0,0162808*MDS_var_stdv - 0,0148205*MDS_var_max + 0,0268176*MDS_hom_sum + 1,09037*MDS_2m_max
5	Altura = 19,6767 - 4,19939*Area - 0,0288903*CHM_sum + 1,36484*CHM_med + 1,54164*MDS_med + 1,47402*MDS_stdv - 1,56801*MDS_max + 353,417*Red_med + 132,716*Gre_stdv - 22,2697*NIR_med - 20,9541*RE_stdv + 1,63368*NDVI_sum + 20,9214*NDVI_stdv - 18,9835*NDRE_stdv
6	Altura = 5,39405 + 0,0629644*CHM_var_med + 0,0608712*CHM_var_stdv - 0,0408762*CHM_var_max - 0,718338*CHM_dis_stdv + 0,00793558*MDS_var_med - 0,00846142*MDS_var_max + 1,22399*MDS_2m_max + 0,0044048*Red_var_med + 0,0605742*Red_con_med + 0,00849724*Gre_var_stdv - 0,0373326*Gre_con_med + 0,0281107*Gre_ent_sum + 0,469612*NIR_dis_stdv - 0,110831*RE_con_med
7	Altura = 13,7314 + 2,46871*CHM_med + 1,03434*CHM_stdv + 0,807101*MDS_med + 1,12979*MDS_stdv - 0,83418*MDS_max + 362,363*Red_stdv + 1,07345*RE_sum + 33,2714*RE_med + 21,4217*NDVI_stdv - 12,4395*NDRE_stdv - 0,000757697*CHM_var_sum - 0,0243339*CHM_var_med - 0,0208324*CHM_var_max - 0,222883*CHM_dis_max + 1,15904*MDS_2m_max - 0,0402991*Red_var_stdv - 0,0482599*RE_var_med + 0,0142909*RE_var_stdv - 0,0750408*RE_con_med

Equações para volume - Talhão *Pinus 2*

Equações – Câmera RGB	
N°	
1	$Vol = -0,326541 + 0,0193859*Area + 0,0468627*CHM_med + 0,0592931*CHM_stdv - 0,0154816*CHM_max$
2	$Vol = -0,132514 - 0,000176169*Red_sum + 0,0114541*Red_stdv + 0,000187008*Gre_sum + 0,00181625*Blue_med - 0,0124977*Intens_stdv$
3	$Vol = -0,0906474 - 0,00133287*Red_var_med + 0,000794868*Red_var_stdv + 0,0376642*Red_dis_med + 0,00189888*Red_ent_sum + 0,000872955*Gre_var_med - 0,0017734*Gre_con_med + 0,00120546*Blue_var_med - 0,00137719*Blue_var_stdv + 0,00188756*Blue_con_med - 0,0386278*Blue_dis_med$
4	$Vol = 0,328337 + 0,00225309*CHM_var_med + 0,00354826*CHM_var_stdv - 0,0013871*CHM_var_max - 0,00508657*CHM_con_stdv + 0,00000323014*MDS_var_sum + 0,00135009*MDS_var_med + 0,00132545*MDS_var_stdv - 0,0014146*MDS_var_max - 0,37119*MDS_hom_med - 0,00991341*MDS_dis_sum + 0,0793197*MDS_dis_stdv + 0,00879672*MDS_ent_sum - 0,165222*MDS_ent_med - 0,0446744*MDS_ent_stdv$
5	$Vol = 0,00141673*CHN_sum + 0,0193364*CHM_stdv - 0,0100602*CHM_max - 0,0000119662*MDS_sum + 0,00385736*Red_stdv + 0,000324997*Gre_sum + 0,00165893*Blue_med - 0,00183012*Blue_stdv - 0,000333692*Intens_sum - 0,00352057*Intens_stdv$
6	$Vol = -0,064504 + 0,00162564*CHM_var_med + 0,00170272*CHM_var_stdv - 0,000857755*CHM_var_max - 0,00800899*CHM_dis_max + 0,000762556*MDS_var_med + 0,00090121*MDS_var_stdv - 0,00077258*MDS_var_max + 0,000809554*MDS_ent_sum - 0,012254*MDS_ent_max - 0,00000852752*Red_var_sum + 0,00538139*Red_dis_med + 0,000698967*Gre_var_stdv + 0,0000338236*Blue_var_sum - 0,00141419*Blue_var_stdv - 0,000843365*Blue_con_med$
7	$Vol = -0,36652 + 0,0426657*CHM_med + 0,0347051*CHM_stdv - 0,0124755*Gre_stdv + 0,0000402278*Blue_sum + 0,0012903*Intens_med + 0,0122875*Intens_stdv - 0,000616305*CHM_var_max - 0,00904481*CHM_dis_max - 0,0000127054*MDS_var_max - 0,000454621*Red_var_med + 0,000618736*Gre_var_stdv + 0,00685848*Gre_dis_med + 0,038245*Gre_ent_stdv + 0,0000124063*Blue_var_sum - 0,00110428*Blue_var_stdv - 0,000432597*Blue_dis_sum$
Equações – Câmera NIR	
1	$Vol = -0,11165*Area + 0,0447292*CHM_med + 0,0338378*CHM_stdv - 0,00694734*CHM_max + 0,0000349141*MDS_sum + 0,0225516*MDS_med + 0,0349592*MDS_stdv - 0,0229123*MDS_max$
2	$Vol = -0,0646765 + 0,00000476622*Red_sum + 0,00000232706*NIR_med - 0,00000296311*NIR_stdv - 0,00000454703*Intens_sum$
3	$Vol = -0,105382 + 0,0000686359*Red_var_sum + 0,000717009*Red_var_med - 0,0000920048*Red_con_sum + 0,016888*Red_2m_sum - 0,0000718023*Gre_var_sum - 0,0601866*Gre_hom_med + 0,0234503*Gre_dis_stdv - 0,000187673*NIR_var_med + 0,00236952*NIR_ent_sum$
4	$Vol = -0,164062 + 0,0027995*CHM_var_med + 0,00383515*CHM_var_stdv - 0,00168298*CHM_var_max - 0,000232476*CHM_con_sum + 0,0000030608*MDS_var_sum + 0,00100842*MDS_var_med + 0,000887239*MDS_var_stdv - 0,00105732*MDS_var_max + 0,00210175*MDS_hom_sum + 0,00273841*MDS_ent_sum + 0,0528798*MDS_2m_med$
5	$Vol = -0,0426003*Area + 0,00108247*CHM_sum + 0,0153391*CHM_med + 0,0398814*CHM_stdv - 0,0117336*CHM_max + 0,00000343793*Red_sum - 0,000053985*Red_stdv - 1,53053E-7*NIR_sum - 0,00000298211*Intens_sum + 0,0000514461*Intens_stdv$
6	$Vol = -0,100249 + 0,0029047*CHM_var_med + 0,00437362*CHM_var_stdv - 0,00198697*CHM_var_max - 0,0193327*CHM_dis_stdv + 9,1035E-7*MDS_var_sum - 0,00102393*MDS_var_stdv - 0,00138615*MDS_2m_sum + 0,00134994*Red_var_med - 0,000865369*Red_dis_sum + 0,0118837*Red_dis_stdv - 0,0784147*Red_ent_stdv + 0,0303964*Red_2m_sum - 0,0008147*Gre_var_med - 0,0490125*Gre_hom_med + 0,0000105109*NIR_var_sum - 0,000454145*NIR_var_med + 0,0080056*NIR_dis_med$
7	$Vol = -0,273621 + 0,070688*CHM_med + 0,0226099*CHM_stdv - 0,0216534*MDS_stdv + 0,0000648594*Red_med - 0,0000443491*Red_stdv - 0,0000197746*NIR_med - 0,0000267942*Intens_med + 0,0000386898*Intens_stdv + 0,00264579*CHM_var_stdv - 0,00145584*CHM_var_max - 0,00413496*CHM_con_stdv - 0,000723901*MDS_2m_sum - 0,0000234179*Red_var_sum + 0,0830983*Red_hom_stdv - 0,0541479*Red_ent_md - 0,00070056*Gre_var_med + 0,0000297804*NIR_var_sum + 0,000183108*NIR_var_stdv$
Equações – Câmera Multi	
1	$Vol = 0,549314 + 0,0241091*CHM_med + 0,0229074*CHM_stdv + 0,00000565067*MDS_sum + 0,125914*MDS_med + 0,167672*MDS_stdv - 0,126783*MDS_max$
2	$Vol = 0,0212475 + 4,73296*Red_stdv + 0,215914*Gre_sum - 1,26727*RE_stdv + 0,326753*NDRE_med - 0,683836*NDRE_stdv$
3	$Vol = 0,0000263708*Red_var_sum - 0,000126234*Red_con_sum + 0,00122065*Red_ent_sum + 0,00747507*Gre_2m_sum + 0,0000223222*NIR_var_sum + 0,000413138*NIR_var_stdv - 0,00542204*NIR_con_med + 0,00523923*NIR_con_stdv - 0,0000142664*RE_var_sum - 0,000163944*RE_con_sum + 0,139729*RE_2m_med$
4	$Vol = -0,0877454 + 0,00387775*CHM_var_med + 0,00446584*CHM_var_stdv - 0,00305053*CHM_var_max + 0,0046168*CHM_ent_sum - 0,0810124*CHM_ent_med + 0,000815166*MDS_var_med + 0,00133745*MDS_var_stdv - 0,000827915*MDS_var_max - 0,0806442*MDS_con_stdv + 0,0214935*MDS_con_max + 0,0539944*MDS_2m_max$
5	$Vol = 0,744417 + 0,0229553*CHM_med + 0,00000530503*MDS_sum + 0,104117*MDS_med + 0,146014*MDS_stdv - 0,105208*MDS_max + 3,99515*Gre_med + 1,82007*NIR_stdv - 0,252084*RE_med - 2,41846*RE_stdv + 0,492707*NDVI_stdv$
6	$Vol = 0,00333392*CHM_var_med + 0,00379483*CHM_var_stdv - 0,00264347*CHM_var_max + 0,00428144*CHM_ent_sum - 0,0861087*CHM_ent_med + 0,000596953*MDS_var_med + 0,000488874*MDS_var_stdv - 0,000612629*MDS_var_max + 0,0145131*MDS_ent_stdv + 0,000301535*Red_var_med - 0,000121087*Red_con_sum + 0,0000144485*Gre_var_sum + 0,000479203*NIR_var_stdv - 0,000204686*RE_var_med - 0,000223921*RE_con_sum + 0,00242494*RE_con_stdv$
7	$Vol = 0,00377581*CHM_sum - 0,0000197228*MDS_sum + 0,0493966*MDS_med + 0,0716185*MDS_stdv - 0,0496845*MDS_max - 6,52905*Red_stdv + 0,406015*Gre_sum + 9,63772*Gre_stdv - 0,0623195*NIR_sum + 1,27286*NIR_stdv + 0,116484*RE_sum - 2,87021*RE_stdv + 1,47952*NDVI_stdv + 0,665006*NDRE_med - 0,404394*NDRE_stdv - 0,000132485*CHM_var_sum + 0,00247908*CHM_var_med + 0,0023663*CHM_var_stdv - 0,00173912*CHM_var_max - 0,00114437*CHM_2m_sum - 0,0246653*MDS_con_med + 0,000743739*MDS_ent_sum + 0,0294862*MDS_2m_max - 0,00300313*Red_dis_sum + 0,0591335*Red_dis_med - 0,0000358471*Gre_var_sum - 0,00112668*Gre_var_stdv - 0,0005021*NIR_dis_sum - 0,0000513278*RE_var_sum + 0,00212452*RE_var_stdv$